

Luis Felipe Gomes de Oliveira

Pietro Teruya Domingues

# **Plataforma em Realidade Virtual para auxílio de treinamento de residentes em cirurgia**

São Paulo

2018

Luis Felipe Gomes de Oliveira  
Pietro Teruya Domingues

## **Plataforma em Realidade Virtual para auxílio de treinamento de residentes em cirurgia**

Texto apresentado à Escola Politécnica da Universidade de São Paulo como requisito para a conclusão do curso de graduação em Engenharia Mecatrônica, junto ao Departamento de Engenharia Mecatrônica e de Sistemas Mecânicos (PMR).

Escola Politécnica da Universidade de São Paulo

Orientador: Prof. Dr. Thiago de Castro Martins

São Paulo  
2018

# Agradecimentos

Em primeiro lugar agradeço a Deus e a Nossa Senhora, por tudo que passei até chegar ao encerramento desse ciclo. Agradeço aos meus pais, Valdir e Gilda, pelo apoio e por terem me acompanhado em todos os momentos, por serem meus motivos e exemplos de vida. Agradeço a toda minha família e aos meus padrinhos, Wilson e Vilani, que sempre vibraram com minhas conquistas e ajudaram quando puderam.

Aos meus amigos Caio, Gustavo e toda a turma da Mecatrônica de 2014, obrigado por terem compartilhado os momentos bons e ruins dessa jornada e pelo privilégio de representar pessoas tão excepcionais como vocês. À turma de 2015, obrigado por acolherem a todos tão bem e por serem os melhores calouros. Aos meus veteranos do PET Mecatrônica e ao nosso tutor, obrigado pela convivência, pelos ensinamentos e pela oportunidade de contribuir com grandes projetos.

Obrigado à minha dupla neste trabalho, Pietro, por ser uma pessoa brilhante mesmo nos momentos mais difíceis e sem a qual esse trabalho não seria possível.

Agradeço ao nosso orientador, por não ter desistido de nós e por nos ajudar sempre que pedimos, e a todos os outros professores que fizeram parte da minha formação como Engenheiro.

À Escola Politécnica da USP e seus funcionários, muito obrigado.

Luis Felipe Gomes de Oliveira

Gostaria de agradecer aos meus pais, Gilson e Kellyn, que prezaram pela minha formação acadêmica e humana desde a infância, e que sem eles não poderia concluir mais este ciclo de forma satisfatória. Agradeço a companhia da minha cachorra Laika que durante parte da graduação foi muito importante.

Agradeço ao apoio de todos os meus amigos próximos do ensino médio, da faculdade e de tantos outros lugares da vida que estiveram presentes e foram pilares importantes em todo este período, na minha formação não apenas acadêmica e intelectual, mas humana.

Também sou grato pelo imprenscindível apoio e presença da minha dupla e amigo Luis Felipe, que não só possibilitou o andamento deste trabalho final, mas também sempre me apoiou em momentos mais críticos.

Agradeço ao nosso orientador, Thiago de Castro Martins, pela paciência e disponibilidade, e pelas valiosíssimas discussões que conduziram nosso trabalho até este resultado.

Pietro Teruya Domingues

# Resumo

Com base nas necessidades levantadas por médicos da FMUSP no contexto das cirurgias hepáticas, busca-se neste trabalho uma solução para auxiliar o treinamento dos futuros cirurgiões, visto que fatores como as particularidades anatômicas do fígado, as limitações em atividades práticas e a dificuldade na análise de imagens bidimensionais de Tomografia Computadorizada (TC), prejudicam seu processo de aprendizagem. O objetivo é desenvolver uma plataforma em Realidade Virtual (RV) para visualização e manipulação de modelos tridimensionais do fígado humano, obtidos a partir da segmentação de imagens de Tomografia Computadorizada. Para tanto, utilizou-se o Oculus Rift DK2 e o sensor Leap Motion, integrados à plataforma de criação de jogos Unity. Foi possível realizar a segmentação do fígado e seus vasos por meio de algoritmos próprios, reconstruir as estruturas e desenvolver um sistema em RV para comparar seções do modelo 3D com as respectivas imagens de TC. **Palavras-chave:** Realidade Virtual. Fígado. Tomografia. Reconstrução (Geometria e Modelagem Computacional). Visualização. Educação Médica.

# Abstract

Based on the needs identified by physicians of FMUSP in the context of liver surgeries, this project looks for a solution to support the training of future surgeons, since factors such as the anatomical particularities of the liver, limitations in practical activities and the difficulty in the analysis of two-dimensional Computed Tomography (CT) images, impair their learning process. The objective is developing a Virtual Reality (VR) platform for visualization and manipulation of three-dimensional models of the human liver, obtained from the segmentation of CT images. The Oculus Rift DK2 and the Leap Motion sensor were integrated with the Unity gaming platform. It was possible to segment the liver and its vessels through the using of own algorithms, to reconstruct the structures and to develop an VR system to compare sections of the 3D model with the respective CT images.

**Keywords:** Virtual Reality. Liver. Tomography. Reconstruction (Geometry and Computational Modeling). Visualization. Medical Education.

# **Lista de ilustrações**

Figura 1 – Anatomia morfológica do fígado. Face ântero-superior . . . . .	15
Figura 2 – Anatomia morfológica do fígado. Face pôstero-inferior . . . . .	16
Figura 3 – Anatomia funcional do fígado. Segmentos de Couinaud. . . . .	16
Figura 4 – Imagem tomográfica do abdômen (caso 5) . . . . .	19
Figura 5 – Região retangular e o respectivo recorte aplicado na imagem de TC .	21
Figura 6 – Exemplo de dilatação morfológica . . . . .	22
Figura 7 – Exemplo de erosão morfológica . . . . .	22
Figura 8 – Exemplo de rotulação por conectividade . . . . .	23
Figura 9 – Segmentação do fígado . . . . .	24
Figura 10 – Seleção das regiões em azul . . . . .	24
Figura 11 – Histograma obtido na região de interesse . . . . .	25
Figura 12 – Oculus Rift (a) com Leap Motion (b) acoplado . . . . .	31
Figura 13 – Modelo reconstruído do fígado . . . . .	33
Figura 14 – Modelo reconstruído dos vasos hepáticos . . . . .	34
Figura 15 – Comparação de áreas segmentadas para o fígado . . . . .	36
Figura 16 – Comparação de áreas segmentadas para os vasos hepáticos . . . . .	37
Figura 17 – Navegação pelo menu principal . . . . .	38
Figura 18 – Navegação pelo Modo Livre . . . . .	39
Figura 19 – Sobreposição da tomografia com a seção do modelo . . . . .	39

# **Lista de tabelas**

Tabela 1 – Informações das TCs utilizadas para a segmentação . . . . .	19
Tabela 2 – Requisitos Funcionais . . . . .	28
Tabela 3 – Requisitos Não-Funcionais . . . . .	29
Tabela 4 – Módulos utilizados para a implementação da plataforma . . . . .	32
Tabela 5 – Métricas da segmentação para o fígado . . . . .	36
Tabela 6 – Métricas da segmentação para os vasos hepáticos . . . . .	36
Tabela 7 – Especificações mínimas para uso do OR . . . . .	40

# **Lista de abreviaturas e siglas**

TC	Tomografia Computadorizada
RM	Ressonância Magnética
RV	Realidade Virtual
OR	Oculus Rift
LM	Leap Motion
DICOM	Digital Imaging and Communications in Medicine
HDM	Head Mounted Display
FMUSP	Faculdade de Medicina da Universidade de São Paulo
PNG	Portable Network Graphics
SDK	Software Development Kit
STL	STereoLithography

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>10</b>
1.1	Tema	10
1.2	Justificativa da Escolha do Tema	10
1.3	Estado da Arte	11
<b>2</b>	<b>ANATOMIA DO FÍGADO</b>	<b>15</b>
<b>3</b>	<b>IMAGENS MÉDICAS</b>	<b>18</b>
3.1	Tomografia Computadorizada	18
3.2	DICOM	18
<b>4</b>	<b>SEGMENTAÇÃO E RECONSTRUÇÃO</b>	<b>20</b>
4.1	Método para Segmentação do Fígado	20
4.2	Método para Segmentação dos Vasos	23
4.3	Reconstrução	26
<b>5</b>	<b>REQUISITOS DO PROJETO</b>	<b>27</b>
5.1	Requisitos Funcionais	27
5.2	Requisitos Não-Funcionais	27
<b>6</b>	<b>ANÁLISE E DESIGN</b>	<b>30</b>
6.1	Unity	30
6.2	Oculus Rift	30
6.3	Leap Motion	31
<b>7</b>	<b>IMPLEMENTAÇÃO</b>	<b>32</b>
<b>8</b>	<b>RESULTADOS</b>	<b>33</b>
8.1	Segmentação	33
8.2	Plataforma em RV	38
8.2.1	Limitações do sistema	40
<b>9</b>	<b>CONCLUSÃO</b>	<b>41</b>
<b>10</b>	<b>SUGESTÕES PARA TRABALHOS FUTUROS</b>	<b>42</b>
	<b>REFERÊNCIAS</b>	<b>43</b>

# 1 Introdução

## 1.1 Tema

O objetivo deste projeto foi desenvolver uma plataforma em Realidade Virtual para visualização e manipulação de modelos tridimensionais do fígado humano, obtidos a partir da segmentação de imagens de Tomografia Computadorizada.

## 1.2 Justificativa da Escolha do Tema

O tema deste trabalho teve origem a partir das necessidades identificadas por médicos representantes da Faculdade de Medicina da Universidade de São Paulo (FMUSP), no que tange à formação prática de futuros profissionais no ramo de cirurgias hepáticas, sobretudo, em relação à análise de imagens de fígado obtidas por TC.

Apesar da complexidade de suas funções, o fígado é um órgão de aparência homogênea, o que torna a anatomia hepática um tema de discussão desafiador (JUZA; PAULI, 2014). Os resultados de (DE FREITAS et al., 2018) demonstram a variabilidade da anatomia do sistema arterial hepático e alertam para a necessidade de cautela nas dissecções cirúrgicas. Tendo em vista essas particularidades anatômicas do fígado, observa-se que cirurgiões em treinamento apresentam uma curva de aprendizado relativamente vagarosa, visto que as oportunidades de aprendizagem formal são limitadas e apenas a anatomia hepática básica é ensinada aos estudantes de medicina (CROSSINGHAM et al., 2009).

Imagens de TC têm sido utilizadas largamente em diagnóstico de doenças e medidas de volume para planejamento cirúrgico e transplantes (OLIVEIRA, 2009), contudo as condições de análise de tomografias computadorizadas ainda são basicamente visuais (KAKINUMA et al., 1999) e de acordo com (LI et al., 2002) isso torna-se uma fonte de erros. Os procedimentos cirúrgicos hepáticos exigem que o cirurgião esteja confortável o suficiente com a anatomia do órgão para poder confiar em sua própria reconstrução mental tridimensional das imagens bidimensionais providas por TC. A interpretação das imagens, no entanto, não é fácil e para os estudantes trata-se de uma tarefa que dificulta suas experiências educacionais em atividades cirúrgicas (CROSSINGHAM et al., 2009).

Dessa forma, sendo a experiência prática uma parte essencial da educação médica, é fundamental para os estudantes terem experiência com o ambiente hospitalar, a comunicação com o paciente, as ferramentas e os aparelhos médicos. No entanto, surgem uma série de limitações em relação à quantidade de experiências práticas as quais um estudante seria exposto durante sua educação. Com o objetivo de superar esses desafios, a

área médica recorre à tecnologia 3D ([GÅSBAKK; SNARBY, 2017](#)).

Conforme verificado por ([BEERMANN et al., 2010](#)), métodos de ensino de anatomia que empregam recursos tridimensionais são mais efetivos do que os que utilizam recursos bidimensionais. Em seu trabalho, duas turmas de estudantes (com 160 indivíduos no total), foram aleatoriamente separadas: uma tendo aulas com apresentações de imagens tridimensionais e outra com apresentações de imagens bidimensionais para aprendizagem da anatomia hepática. Os estudantes foram avaliados posteriormente através de um questionário e verificou-se que aqueles que tiveram contato com os recursos tridimensionais obtiveram um número显著mente maior de acertos, em comparação aos demais estudantes. Ainda nesse contexto, ambientes de visualização 3D têm sido empregados por médicos para o planejamento, simulação e treinamento de diversos tipos cirúrgicas, gerando resultados positivos, sobretudo para o tratamento dos pacientes. Entre os tipos de ambiente utilizados, pode-se destacar aqueles que se baseiam em Realidade Virtual.

Então, este trabalho propõe o uso de uma plataforma em RV para auxiliar os cirurgiões em processo de treinamento a compreender e praticar a análise de tomografias do fígado, a partir da reconstrução tridimensional do órgão por meio de imagens de TC.

### 1.3 Estado da Arte

Um exemplo específico de sistema de visualização para ensino de anatomia do fígado foi desenvolvido por ([CROSSINGHAM et al., 2009](#)). Na plataforma proposta, os modelos tridimensionais dos fígados segmentados foram obtidos a partir de imagens de Tomografia Computadorizada (TC) e reconstruídos, remodelados, texturizados e colorizados manualmente em softwares de modelagem 3D. A partir deste modelo, foi desenvolvida uma interface de página web de navegação tridimensional onde o usuário pode manipular espacialmente o fígado, ver suas estruturas anatômicas e determinadas seções.

Sistemas de treinamento cirúrgico baseados em Realidade Virtual (RV) podem representar um melhor custo-benefício e uma alternativa eficiente aos métodos tradicionais de treinamento. Adicionalmente, a RV é uma tecnologia que pode ensinar aos cirurgiões novos procedimentos e pode determinar o nível de competência desses cirurgiões em treinamento, antes de operarem pacientes ([KÜHNAPFEL; CAKMAK; MAASS, 2000](#)). Foi observado por ([SEYMOUR et al., 2002](#)) em seu trabalho que a rapidez do processo de dissecção da vesícula biliar foi 29% maior para os residentes treinados por RV, enquanto os residentes não treinados por RV foram nove vezes mais propensos ao erro e cinco vezes mais propensos a ferir a vesícula biliar ou a queimar um tecido não envolvido no procedimento. Erros médicos foram seis vezes menos prováveis de ocorrer no grupo treinado por RV.

Já são também disponibilizados comercialmente alguns simuladores que empregam RV para o treinamento de neurocirurgiões. Um excelente exemplo desse tipo simulador é o

NeuroTouch, que foi implementado e testado em vários hospitais nos EUA. O simulador consta de duas partes, NeuroTouch Plan e NeuroTouch Sim. O NeuroTouch Plan utiliza imagens de TC e RM para criar um modelo 3D da cabeça humana, que torna possível examinar o cérebro para a preparação da neurocirurgia. Define-se o local de realização da cirurgia e então o usuário é movido para o NeuroTouch Sim, onde se pratica a cirurgia com base no planejamento realizado na primeira parte (GÅSBAKK; SNARBY, 2017).

Entretanto, simuladores cirúrgicos para treinamento ainda não são utilizados em larga escala, apesar do seu aparente sucesso na literatura (GÅSBAKK; SNARBY, 2017). De acordo com (STEFANIDIS et al., 2015) atualmente os simuladores são complexos de construir e implementar, além de exigirem investimentos relativamente elevados. Com base nisso, diferentes alternativas têm sido procuradas e entre elas estão plataformas como o Oculus Rift e o HTC Vive. (MATHUR, 2015) desenvolveu um sistema de treinamento para cirurgiões usando Oculus Rift em conjunto com o dispositivo de entrada de baixo custo Razer Hydra. Os usuários do sistema usam o headset para ver o mundo virtual e os controladores para interagir com ele. Os resultados apresentados mostram que os usuários do sistema se sentem imersos no cenário e podem treinar independentemente de supervisão. Também argumenta-se que aplicações similares têm um grande potencial.

Diferentes técnicas e dispositivos podem ser usados para executar controles e interações nos ambientes RV. Uma das ferramentas que tem sido utilizada para isso é o sensor Leap Motion, que reconhece gestos das mãos e localização tridimensional dos dedos. Os trabalhos realizados por (NAKAGAWA; PENTEADO, 2015) e (SEIF; UMEDA; HIGA, 2017) apresentam interfaces em RV, com manipulação de estruturas anatômicas tridimensionais obtidas a partir de imagens de TC, cujos controles são realizados via LM. (NICOLA et al., 2016) e (BIZZOTTO et al., 2014) apontam que se torna mais rápida a familiarização dos usuários com sistemas que utilizam o LM, sobretudo em aplicações médicas que envolvem a manipulação de órgãos ou outras estruturas; no último ainda é mencionado o baixo custo do dispositivo, o que sugere que esta seria uma ferramenta economicamente mais viável em comparação a outras opções de controladores.

Para ser possível a manipulação dos modelos anatômicos em plataformas virtuais, é necessário processar os dados brutos provindo de TC (ou RM) de órgãos reais e efetuar a segmentação e a reconstrução tridimensional. Atualmente, algoritmos confiáveis são necessários para a delinearção de estruturas anatômicas e regiões de interesse, tanto para planejamento de cirurgias quanto para estudos clínicos (SHARMA; AGGARWAL, 2010).

As técnicas disponíveis de segmentação de imagens médicas são específicas para cada aplicação, tipo de obtenção de imagem, ou parte do corpo a ser estudada. Segundo (SHARMA; AGGARWAL, 2010), há uma série de técnicas de segmentação, da mais básica à mais avançada, como: segmentação por tons de cinza, segmentação por detecção de bordas, segmentação por regiões de pixels com propriedades similares, segmentação

baseada em características da textura, segmentação baseada em modelo pré-determinado, segmentação baseada em classificação não supervisionada e classificação supervisionada.

Um método promissor e extensivamente utilizado é o de segmentação por modelos deformáveis ([XU; PHAM; PRINCE, 2000](#)). Modelos deformáveis são curvas ou superfícies definidas em um domínio da imagem que podem se mover sob influência de forças internas (definidas pela geometria da curva) e forças externas (definidas pelas características da imagem analisada). As forças internas são responsáveis por fornecer suavidade à curva e as forças externas são responsáveis por exercer modificações na curva tal que convirja para as regiões de interesse a serem segmentadas. Vale notar porém, que para a metodologia de modelos deformáveis é necessário pré-determinar a região de interesse e a curva inicial.

Quanto à segmentação em elementos anatômicos, existem aplicações para órgãos como pulmão. Em ([STOECKER et al., 2013](#)), a metodologia desenvolvida é a segmentação do pulmão em seus respectivos lobos, a partir do cálculo da distância dos elementos da imagem em relação à artéria pulmonar. Este trabalho se mostra inovador pois há dificuldades em visualizar as bordas dos lobos a partir das imagens de TC. Porém a segmentação prévia da artéria pulmonar é feita manualmente e a rotulação dos lobos é feita interativamente.

Nos últimos anos, com o uso cada vez mais extensivo de Redes Neurais Convolucionais, foi proposto uma rede para segmentação de imagens biomédicas por ([RONNE-BERGER; FISCHER; BROX, 2015](#)), chamada U-Net. Ela pode ser treinada a partir de relativamente poucas amostras (já pré-segmentadas e classificadas), e usada para segmentar estruturas neurais e células individuais. Segundo os autores, o algoritmo forneceu segmentações significativas com um relativo baixo tempo de processamento.

Um outro trabalho que se utiliza de Redes Neurais Convolucionais para segmentação é o de ([ROTH et al., 2015](#)). Neste trabalho, o objetivo é segmentar imagens de TC de pâncreas. Os autores utilizam uma abordagem “bottom-up”, ou seja, partem de classificação de macro-elementos da imagem e refinam consecutivamente até chegar na segmentação final. Esta abordagem é feita a partir de: segmentar a imagem em superpixels, classificar os superpixels em candidatos potenciais de serem partes do tecido pancreático, utilizar as classificações dos superpixels como parâmetro para a Rede Neural Convolucional que irá tratar os pixels segmentados pelos superpixels. Dessa forma, o algoritmo devolve as regiões onde o pâncreas está presente nas imagens de TC do corpo humano.

Aplicações específicas para segmentação de fígado também existem na literatura. Em ([CHEN et al., 1998](#)), a proposta é identificar os contornos do fígado numa imagem de TC e depois classificar tumores presentes no fígado utilizando uma Rede Neural. O algoritmo primeiro utiliza um modelo de Fractional Brownian Motion para esboçar os contornos e depois utiliza um Modelo Deformável para delinear precisamente os contornos do fígado. Depois de segmentado o fígado, são extraídas informações dos tumores por meio

de Spatial-Level Co-Ocurrence Matrices, uma técnica utilizada para classificação de textura que leva em conta a correlação espacial de pares de tons de cinza. Essas informações de textura são então utilizadas para uma rede neural que classifica o tipo de tumor do fígado. Em todos os casos, o fígado foi segmentado corretamente e em 83% dos casos o tipo de tumor foi classificado de acordo com o tipo real.

Outra aplicação criada especificamente para segmentação automática de fígado, está em ([DOU et al., 2016](#)). O objetivo deste trabalho é a segmentação automática do órgão a partir da sua estrutura tridimensional. As imagens são obtidas a partir de um conjunto de imagens brutas sem nenhuma pré-segmentação. O trabalho se baseia em redes neurais convolucionais e Conditional Random Fields. A estratégia proposta se aproveita da estrutura tridimensional, ou seja, utiliza-se de vários cortes de imagens de TC para efetuar a segmentação. Conforme os autores, o método se revela mais rápido que os métodos de classificação automáticos presentes anteriormente.

## 2 Anatomia do Fígado

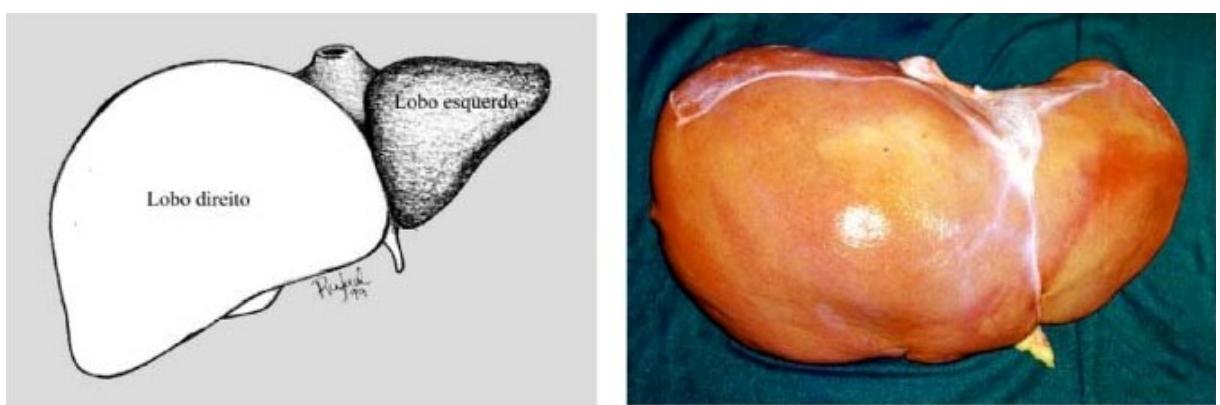
Neste capítulo são apresentadas as principais características da anatomia do fígado, que poderão servir como parâmetro de comparação e análise dos modelos tridimensionais construídos neste trabalho.

O fígado é o maior órgão em volume no ser humano, ocupando 2,5% do peso total do corpo e desempenhando uma série de funções necessárias para manter a homeostase fisiológica normal, desde a participação no metabolismo dos carboidratos, gordura e proteínas, até a atuação em mecanismos de defesa. Trata-se de uma glândula, localizada imediatamente abaixo do diafragma, no quadrante superior direito do abdômen, com uma pequena porção também ocupando a metade esquerda do abdômen.

Por conta de suas diferentes particularidades, a anatomia do fígado é descrita de duas formas distintas, considerando aspectos morfológicos ou aspectos funcionais do órgão.

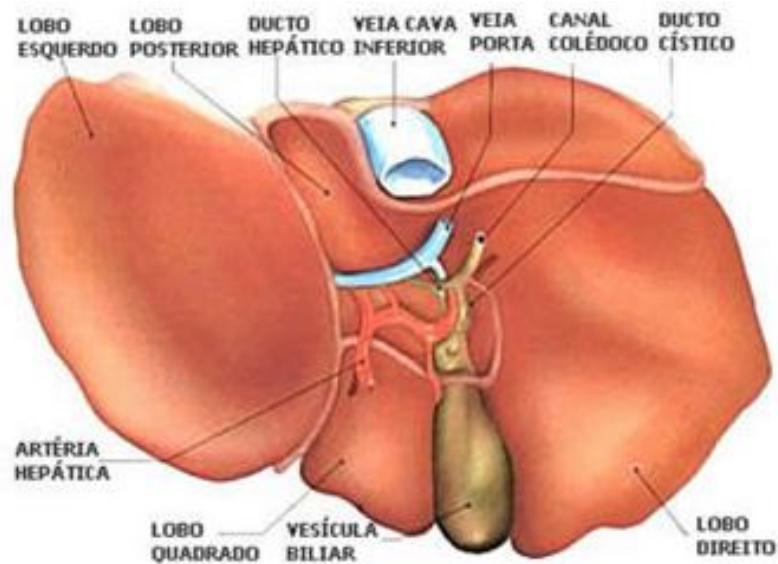
Em termos morfológicos, o fígado apresenta duas faces (figuras 1 e 2): uma em relação ao diafragma (diafragmática ou ântero-superior) e outra em contato com as vísceras (visceral ou pôsterior-inferior). Nesta última, são identificados quatro lobos: direito e esquerdo (os dois maiores); quadrado e caudado (os dois menores). Na face diafragmática os lobos maiores são separados por uma prega do peritônio, o ligamento falciforme, e na outra face são separados pela fissura umbilical. A face inferior mostra ainda que: entre os lobos direito e quadrado encontra-se a vesícula biliar; entre os lobos direito e caudado há um sulco que aloja a veia cava inferior; entre os lobos quadrado e caudado há uma fenda transversal (a porta do fígado, fissura transversa ou hilar) por onde penetram no parênquima hepático os ramos da veia porta, da artéria hepática e os ductos biliares ([FATTINI; DANGELO, 2007](#); [TRIVIÑO; ABIB, 2003](#)).

Figura 1 – Anatomia morfológica do fígado. Face ântero-superior



Fonte: ([TRIVIÑO; ABIB, 2003](#))

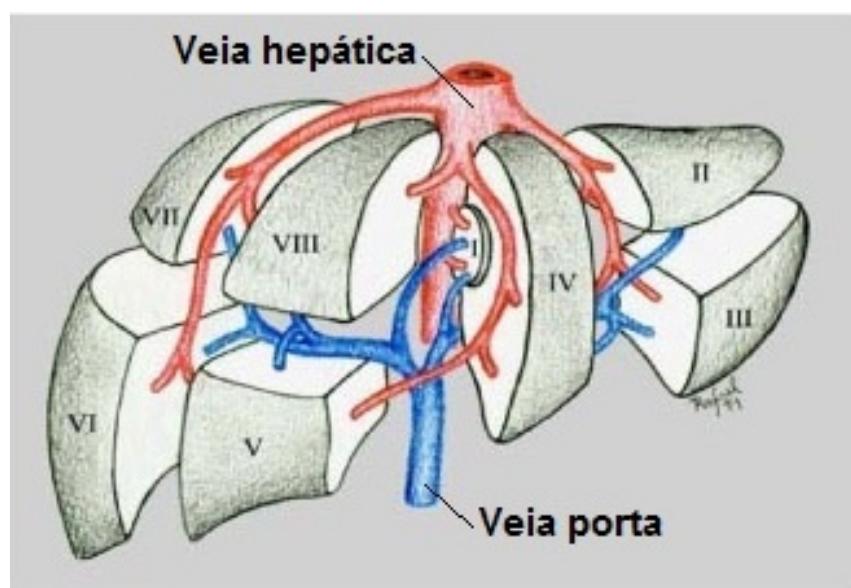
Figura 2 – Anatomia morfológica do fígado. Face póstero-inferior



Fonte: ([RIBEIRO, 2018](#))

A anatomia hepática funcional descrita por ([COUINAUD; DELMAS; PATEL, 1957](#)), divide o fígado em hemifígado direito e esquerdo, cada qual, por sua vez, é dividido em setores e segmentos definidos pelos ramos da veia porta e da veia hepática (figura 3). Esses segmentos são absolutamente individualizados no que diz respeito aos fluxos portal e arterial, drenagem biliar e drenagem venosa, sendo, portanto, distintos funcionalmente ([TRIVIÑO; ABIB, 2003](#)).

Figura 3 – Anatomia funcional do fígado. Segmentos de Couinaud.



Fonte: ([TRIVIÑO; ABIB, 2003](#))

Determinados tipos de tratamentos cirúrgicos do fígado normalmente empregam a retirada desses segmentos funcionais (OLIVEIRA, 2009). Portanto, é importante que os cirurgiões em formação desenvolvam a habilidade de definir essas regiões, a partir da análise de imagens bidimensionais.

Têm-se por objetivo neste trabalho obter modelos que representem apenas o fígado propriamente dito e seus vasos, não contemplando outras estruturas externas anexas, como a vesícula biliar, e nem evidenciando os ligamentos do órgão.

# 3 Imagens Médicas

Neste capítulo são apresentadas as principais características sobre as imagens médicas utilizadas neste trabalho, bem como sobre seu método de obtenção, a Tomografia Computadorizada.

## 3.1 Tomografia Computadorizada

A TC é um tipo de exame radiológico (ou seja, obtido através de emissão de raios X) utilizado para aplicações clínicas desde o início da década de 70. Para realização desse exame, uma fonte de raios-X é acionada, emitindo um feixe de radiação em forma de leque, ao mesmo tempo em que realiza um movimento circular ao redor do paciente. No lado oposto a essa fonte, está localizada uma série de detectores que transformam a radiação que atravessa o corpo em um sinal elétrico que é convertido em imagem digital em matizes de cinza. Cada imagem corresponde a um corte fino ("fatia") da estrutura interna a ser analisada e a intensidade (brilho) da imagem corresponde a absorção dos raios-X, que depende da densidade dos tecidos internos, podendo ser medida por meio de uma escala específica (unidades Hounsfield). Dessa forma é possível fazer um mapeamento e representação das partes internas do indivíduo de modo não invasivo, o que auxilia no diagnóstico de alterações como, por exemplo, uma massa sólida de um cisto ou tumor (AMARO JÚNIOR; YAMASHITA, 2001; OLIVEIRA, 2009).

## 3.2 DICOM

Dada a existência de distintos métodos para obtenção de imagens médicas (e mesmo considerando um único tipo de método como a TC) podem ser encontradas diferenças quanto ao formato de apresentação dos dados de cada exame. Surge então a necessidade de padronização para possibilitar a troca confiável de informações entre especialistas (BIDGOOD JR et al., 1997). É para atender a essa necessidade que surge então o padrão DICOM.

DICOM é a sigla para Digital Imaging Communications in Medicine. Trata-se da denominação atual para o protocolo desenvolvido pelo American College of Radiology e a National Electrical Manufacturers Association, que determina, entre outros elementos, um formato padrão para imagens médicas. Esse protocolo permite que informações associadas à imagem, ao paciente, ao aparelho e instituto responsáveis pela aquisição, sejam compartilhadas entre computadores, hospitais e outros equipamentos de imagem (OLIVEIRA, 2009).

Este trabalho utiliza imagens de TC no formato DICOM, obtidas a partir do banco de dados [3D-IRCADB-01](#), disponibilizado online pelo Research Institute against Digestive Cancer (IRCAD) France. A base de dados contém, entre outros arquivos, as imagens DICOM de TCs anonimizadas de 10 mulheres e 10 homens (portadores de tumores ou não) e as respectivas máscaras para realização da segmentação dos órgãos.

Para a segmentação e construção dos modelos tridimensionais neste trabalho, foram usados os casos 5, 7, 11, 14 e 20, que correspondem a indivíduos sem tumores no fígado. A tabela 1 apresenta as principais informações fornecidas para cada um desses casos.

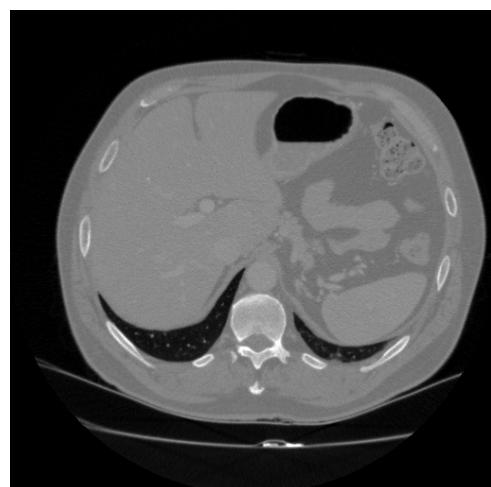
Tabela 1 – Informações das TCs utilizadas para a segmentação

Nº	Sexo	Ano de nascimento	Dimensões do fígado Largura x Profundidade x Altura (cm)	Densidade média do fígado (unidades Hounsfield)
5	M	1957	19,8 x 18,6 x 19,1	69
7	M	1946	24,9 x 15,2 x 16,6	115
11	M	1966	19,1 x 14,4 x 16,2	108
14	F	1970	22,4 x 15,4 x 13,4	109
20	F	1949	20,0 x 16,6 x 16,8	59

Fonte: [3D-IRCADB-01](#)

Para a leitura dos arquivos DICOM das TCs e extração das imagens do fígado em um formato utilizável na plataforma em RV, foi criada uma rotina em Python (utilizando a biblioteca [PYDICOM](#)) que transforma a escala Hounsfield das imagens em TC para uma escala de cor de 255 níveis, usada em arquivos PNG. Um exemplo do resultado dessa conversão é mostrado na figura 4.

Figura 4 – Imagem tomográfica do abdômen (caso 5)



Fonte: [3D-IRCADB-01](#)

# 4 Segmentação e reconstrução

Este capítulo contém a descrição dos algoritmos empregados no processo de segmentação do fígado e seus vasos, incluindo a posterior reconstrução tridimensional do órgão para formação dos modelos utilizados na plataforma. Para implementar os algoritmos automáticos idealizados descritos a seguir, foi utilizada a linguagem Python, com o auxílio da biblioteca de processamento de imagens e visão computacional **OPENCV**, da biblioteca de leitura de DICOM **PYDICOM**, da biblioteca de operação de matrizes **NUMPY**, da biblioteca científica **SCIPY** e da biblioteca para leitura, manipulação e escrita de arquivos STL, a **PYTHONSTL**.

## 4.1 Método para Segmentação do Fígado

A primeira etapa consiste na filtragem 2D de cada imagem com um filtro gaussiano para remoção de ruídos. Esta filtragem é essencial para a correta segmentação, já que esta baseia-se na intensidade dos pixels da imagem. Caso haja muito ruído, haverá uma não-homogeneidade na imagem que impedirá o algoritmo de segmentar as devidas partes corretamente. O filtro gaussiano atua como um atenuador de altas frequências e homogeneíza a imagem localmente.

A segmentação então é feita utilizando-se limiares para a detecção correta da região do fígado. Este método baseia-se no critério de que o fígado está presente em um conjunto de voxels tal que a intensidade ( $I_v$ ) desses voxels seja:

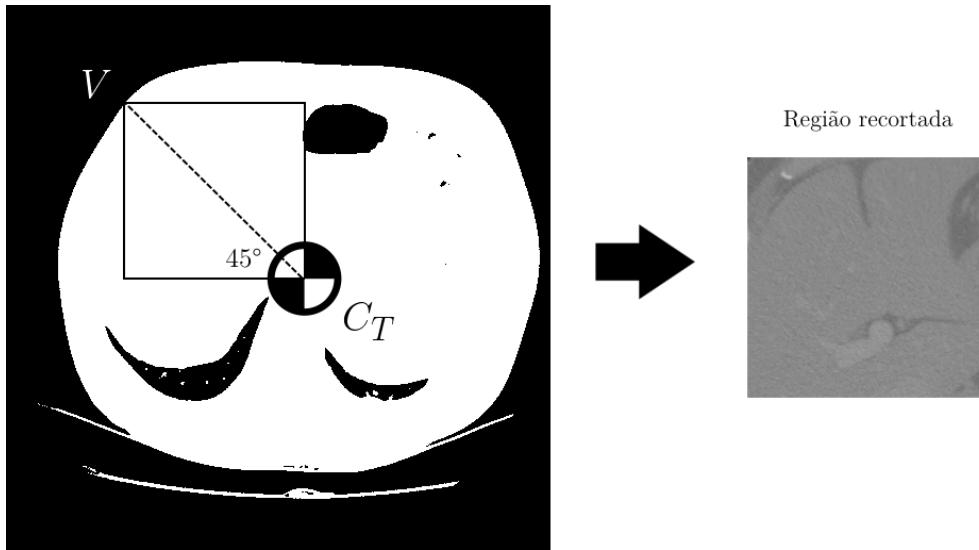
$$\min_L < I_v < \max_L \quad (4.1)$$

Como existem outros órgãos na imagem com intensidade similares a do fígado, também devem ser levadas em conta as características espaciais para a determinação da região correta. Para determinar a localização correta, bem como os parâmetros  $\min_L$  e  $\max_L$ , foi desenvolvido o seguinte algoritmo:

1. Segmentação do tronco: o tronco foi segmentado em todas as fatias conforme o critério de que  $I_v > -800$ , baseado no fato de que para esse limiar há presença de qualquer tecido interno (mole ou duro).
2. Obtenção do baricentro geométrico: para cada fatia, o baricentro geométrico  $C_T$  da região segmentada do tronco foi obtido.

3. Determinação de região retangular: para cada fatia, foi delineado uma região retangular  $R1$  com o vértice em  $C_T$  e outro vértice  $V$  na borda da região segmentada, de tal forma que o ângulo da diagonal do retângulo em relação à horizontal fosse  $45^\circ$ , conforme ilustra a figura 5. Recorta-se então a imagem de TC na região retangular determinada.

Figura 5 – Região retangular e o respectivo recorte aplicado na imagem de TC



4. O desvio padrão  $\sigma_r$  da intensidade da região recortada é então calculado para cada fatia e armazenado em um vetor  $S_\sigma$ .
5. Percorre-se o vetor e a fatia correspondente ao menor  $\sigma_r$  do vetor é selecionada. Na presença do fígado, há uma massa homogênea e uniforme em toda a extensão do recorte superior esquerdo. Um  $\sigma_r$  menor indica fortemente a presença do fígado.
6. Uma quadrado  $R2$  com a metade da área do quadrado previamente selecionado ( $R1$ ) e com o centro geométrico coincidente a  $R1$  é parametrizado e recorta-se a imagem da fatia selecionada anteriormente nos limites deste quadrado  $R1$ . Isto é feito para evitar possíveis efeitos de borda e regiões da costela que podem interferir no próximo procedimento.
7. Calculam-se a média  $\mu_L$  e o desvio padrão  $\sigma_L$  da intensidade da região recortada por  $R2$  da fatia selecionada. Como esta região está inserida em uma região interna correspondente ao fígado, então  $\mu_L$  representa a média de intensidades do tecido hepático e  $\sigma_L$  representa a variação de intensidades.

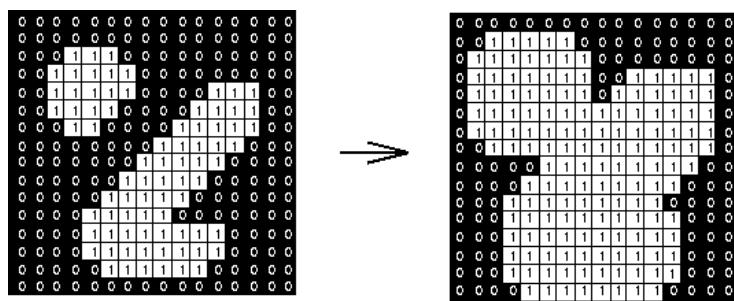
Determinam-se os limiares a partir dos parâmetros quantitativos obtidos, portanto eles são definidos como:

$$\min_L = \mu_L - \sigma_L \quad (4.2)$$

$$\max_L = \mu_L + \sigma_L \quad (4.3)$$

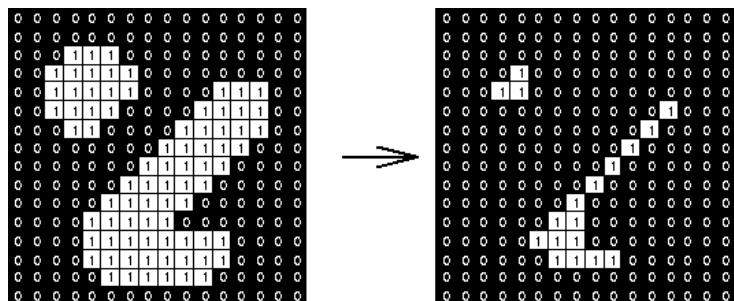
Uma vez que os valores de limiares estão disponíveis, é possível determinar as regiões 3D que cumprem o critério definido pela equação 4.1. Depois da segmentação, as regiões foram tratadas morfológicamente com erosão e posterior dilatação 3D, que faz com que pequenos volumes e conexões estreitas desapareçam, favorecendo a separação de distintas regiões anatômicas. As operações de dilatação e erosão morfológicas são mostradas nas figuras 6 e 7.

Figura 6 – Exemplo de dilatação morfológica



Fonte: UNIVERSITY

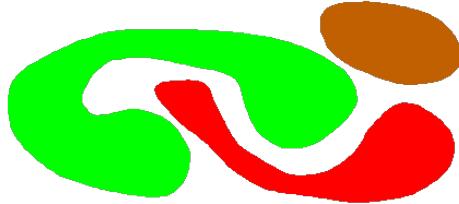
Figura 7 – Exemplo de erosão morfológica



Fonte: UNIVERSITY

Os volumes segmentados então seguem para a separação pela conectividade. Regiões sem conectividade são nomeadas com rótulos numéricos distintos e regiões conexas assumem um único rótulo numérico em toda sua extensão. Um exemplo de rotulação por conectividade é ilustrada na figura 8, onde cada cor corresponde à uma região conexa.

Figura 8 – Exemplo de rotulação por conectividade



Fonte: EDINBURGH

Para filtrar a região correspondente ao fígado, verifica-se a contagem de voxels de rótulos que estejam no quadrante superior esquerdo da fatia. O rótulo que mais ocorre nesta contagem (ou seja, o rótulo com o maior volume) é selecionado. Como o fígado é a maior massa no quadrante superior esquerdo, então a região selecionada corresponde à massa do fígado.

## 4.2 Método para Segmentação dos Vasos

Para a segmentação dos vasos também foi utilizado o critério de comparação com limiares. Portanto, nesta fase da segmentação, os voxels selecionados que representam os vasos do fígado são aqueles em que a intensidade  $I_v$  deve satisfazer:

$$\min_V < I_v < \max_V \quad (4.4)$$

Para se determinar os valores de  $\min_V$  e  $\max_V$ , procedimentos similares aos procedimentos de segmentação do fígado foram utilizados. Portanto, define-se:

$$\min_V = \mu_V - \sigma_V \quad (4.5)$$

$$\max_V = \mu_V + \sigma_V \quad (4.6)$$

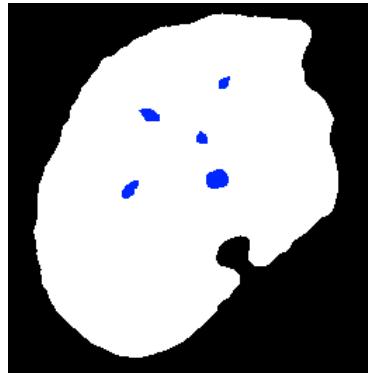
Para determinar as regiões preliminares dos vasos foi utilizado um algoritmo para detectar regiões internas vazias na segmentação preliminar do fígado. Como estas regiões não seguiram o critério de segmentação do fígado, elas não são tecido hepático, contudo, como estão contidas na região segmentada do fígado, permeiam o parênquima hepático. Anatomicamente, os tecidos que correspondem a tais condições são os vasos do fígado.

Estas regiões vazias internas foram então utilizadas como máscara para recortar a imagem de TC e utilizar as intensidades para o cálculo da média  $\mu_V$  e  $\sigma_V$ . A figura 9 ilustra a segmentação obtida do fígado em uma fatia e a figura 10 ilustra as regiões selecionadas a partir da segmentação em azul para a obtenção da máscara.

Figura 9 – Segmentação do fígado



Figura 10 – Seleção das regiões em azul

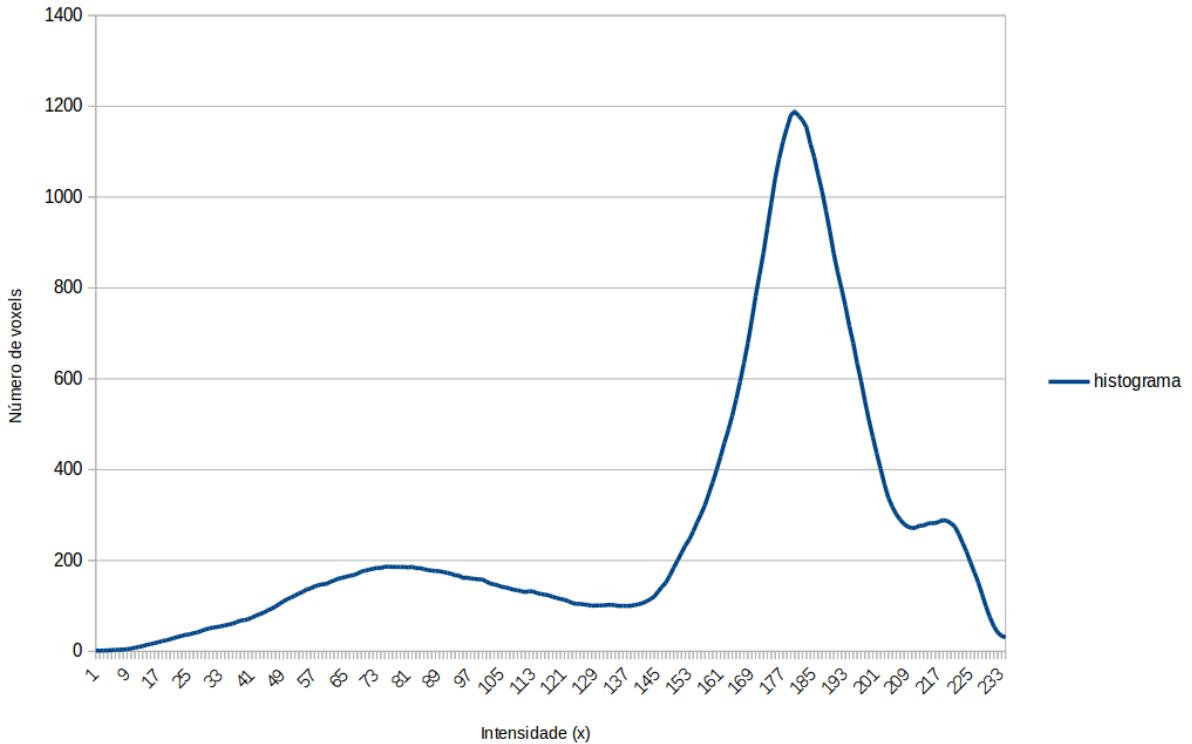


A estimativa foi baseada desta vez na obtenção do histograma das intensidades da região selecionada. Como há tecidos vizinhos e regiões de transição entre o tecido do vaso e o tecido hepático, há existência de classes diferentes de intensidade. Portanto a análise do histograma é necessária para separar corretamente as classes de tecido hepático e tecido vascular. Define-se como  $H(x)$  o valor do histograma em  $x$  (intensidade do voxel), tal que  $I_{min} < x < I_{max}$ , sendo  $I_{min}$  e  $I_{max}$  os limites mínimo e máximo das intensidades obtidas na região. A figura 11 ilustra um exemplo de histograma obtido.

É possível ver a existência de várias classes de intensidade. Sabe-se a princípio que a classe com intensidades maiores corresponde aos vasos sanguíneos. Para determinar a média e desvio padrão da classe dos vasos uma filtragem do histograma foi feita com um filtro de média móvel (com largura 11), e depois a primeira e a segunda derivada em relação à  $x$  foram obtidas. Para se determinar a média  $\mu_V$  busca-se iterativamente um  $x_1$ , com  $x_1$  começando de  $I_{max}$  e descrescendo. Esse  $x_1$  ao ser selecionado deve satisfazer as condições de que:

$$\frac{dH(x)}{dx} = 0 \quad (4.7)$$

Figura 11 – Histograma obtido na região de interesse



$$\frac{d^2 H(x)}{dx^2} < 0 \quad (4.8)$$

Este ponto corresponde ao ponto de máximo local no histograma, o que é análogo à média em uma distribuição normal. Para estimar o desvio padrão  $\sigma_V$  desta classe busca-se da mesma forma iterada um  $x_2$  que satisfaça:

$$\frac{dH(x)}{dx} < 0 \quad (4.9)$$

$$\frac{d^2 H(x)}{dx^2} = 0 \quad (4.10)$$

Este ponto corresponde ao ponto de inflexão, que é análogo ao valor do desvio padrão em uma distribuição normal. Portanto, a partir de  $x_1$  e  $x_2$ , é possível obter:

$$\mu_V = x_1 \quad (4.11)$$

$$\sigma_V = x_2 - x_1 \quad (4.12)$$

Uma vez selecionados os valores de  $\mu_V$  e  $\sigma_V$ , as regiões que seguem os critérios da equação 4.4 são então selecionadas. Análogo à segmentação hepática, regiões são rotuladas numericamente de acordo com sua conectividade.

Uma máscara baseada na segmentação do fígado é então criada, dilatando-se morfologicamente o fígado, o que causa o fechamento dos espaços vazios. Esta máscara é utilizada para contar os voxels das regiões rotuladas dos vasos. O rótulo numérico que mais incidir dentro da máscara é o provável candidato a ser a região vascular hepática e é selecionado. As outras regiões são descartadas.

### 4.3 Reconstrução

As segmentações do fígado e dos vasos são então dilatadas e em seguida, erodidas morfologicamente para eliminar estruturas internas vazias. A segmentação hepática é subtraída da segmentação vascular para não haver sobreposição dos modelos. Depois deste pré-processamento, o algoritmo de cubos marchantes, descrito por ([LORENSEN; CLINE, 1987](#)) é utilizado para construir uma superfície fechada em volta dos voxels segmentados. Dessa forma, obtém-se uma malha tridimensional que representa o fígado e os vasos reconstruídos.

Para melhorar a visualização e compensar os ruídos de alta frequência que surgem na reconstrução por meio de cubos marchantes, um algoritmo de suavização foi aplicado na superfície. Este algoritmo funciona como um filtro de média espacial, ou seja, a cada vez que a suavização é feita, o vértice tende a caminhar para a média dos seus vértices vizinhos.

# 5 Requisitos do Projeto

Nas seções deste capítulo são apresentados os requisitos funcionais e não-funcionais da plataforma desenvolvida em Realidade Virtual. Tais requisitos foram definidos, sobre tudo, a partir das necessidades identificadas pelos médicos da FMUSP, durante o processo de treinamento em cirurgias hepáticas.

## 5.1 Requisitos Funcionais

Por se tratar de um sistema de software, é necessário realizar uma análise criteriosa dos requisitos a serem atendidos pelo sistema (Nakagawa et al., 2015). Os requisitos funcionais do projeto descrevem de maneira textual todas as funcionalidades esperadas para o sistema. A Tabela 2 apresenta os requisitos funcionais especificados para este projeto.

## 5.2 Requisitos Não-Funcionais

Os requisitos não-funcionais indicam aspectos qualitativos que devem estar contidos no sistema. A Tabela 3 lista os principais requisitos não-funcionais adotados neste projeto, baseando-se no trabalho de (NAKAGAWA; PENTEADO, 2015) para o desenvolvimento de um sistema em RV de natureza semelhante.

Tabela 2 – Requisitos Funcionais

#	Nome	Descrição	Objetivo
1	Menu inicial	Modo de navegação pelo ambiente de simulação, que é exibido quando o usuário iniciar o sistema	Definir o modo de inicialização do ambiente de RV, em que o usuário seleciona qual dos outros modos deseja iniciar ou encerra a sessão de uso do sistema
2	Modo Livre	Modo de navegação livre pelo ambiente de simulação contendo o modelo 3D	Permitir ao usuário examinar o fígado e seus vasos, sem restrições de movimento
3	Exibir modelo 3D do fígado e seus vasos	Habilitar/desabilitar a visualização do modelo tridimensional fígado e seus vasos, obtido pelas imagens de TC	Permitir ao usuário selecionar qual estrutura do órgão deseja visualizar
4	Rotacionar, transladar e redimensionar o modelo 3D	Realizar movimentos e rotações nos eixos X, Y e Z, ampliar e reduzir modelo a partir de gestos mapeados	Permitir ao usuário manipular o modelo e escolher o ângulo para visualização do órgão conforme desejado
5	Menu de opções	Exibir um menu interativo para selecionar funcionalidades durante os modos de navegação	Permitir ao usuário executar as funções disponíveis para manipulação do modelo 3D e transitar entre os modos de navegação, retornando ao menu inicial
6	Reconhecer movimento e posição das mãos	Capturar movimentos e posições específicas das mãos, de acordo com os gestos mapeados para realização de controles no ambiente de simulação	Permitir ao usuário integrar de forma intuitiva e simples com sistema
7	Estudo das imagens tomográficas do fígado	Realizar cortes no modelo 3D do fígado e exibir a imagem tomográfica correspondente	Permitir ao usuário comparar as imagens bidimensionais da TC com o modelo tridimensional

Tabela 3 – Requisitos Não-Funcionais

#	Nome	Descrição	Objetivo
1	Intuitividade	O sistema deve ser facilmente operado por um residente em cirurgia	Facilitar o uso dos equipamentos e a interação do usuário com o sistema, levando menos de 5 minutos para familiaridade
2	Imersão	O sistema deve ser imersivo, dado ao usuário a sensação de presença	Permitir que o usuário tenha a sensação de estar imerso no ambiente virtual completamente
3	Não-fadiga	O sistema não deve provocar fadiga/tontura	Permitir o uso prolongado do sistema (por mais de 30 minutos ininterruptos)
4	Escalabilidade	O sistema deve ser escalável	Permitir a expansão e a continuidade do projeto no projeto futuro, bem como o uso em universidades e hospitais
5	Didática	O sistema deve facilitar a aprendizagem do usuário em treinamento para cirurgias hepáticas	Garantir que o sistema alcance os objetivos propostos em seu escopo

# 6 Análise e Design

Neste capítulo são apresentados os principais aspectos das etapas de análise de requisitos e projeto de software, envolvendo uma breve descrição dos periféricos que constituem a solução proposta no trabalho.

## 6.1 Unity

Para o desenvolvimento do software foi utilizada a plataforma de criação de jogos virtuais, Unity. Essa escolha foi realizada, entre outras razões, por conta de: a variedade de recursos disponíveis nessa plataforma para desenvolvedores de diferentes naturezas, incluindo RV (por exemplo, o Unity permite através de funcionalidades nativas o mapeamento de sombras, texturas e de colisão, que não precisariam ser codificadas em baixo nível); sua portabilidade, pois apresenta compatibilidade com 22 plataformas de jogos, incluindo navegadores Web, Windows, Mac, Android, iOS, PlayStation e Xbox; a grande comunidade de usuários ao redor do mundo, o que garante a existência de suporte para essa ferramenta. Além disso, é um serviço que apresenta uma versão gratuita totalmente funcional e que é compatível com os periféricos usados no projeto (NAKAGAWA; PENTEADO, 2015). A versão utilizada neste trabalho foi a [UNITY 2018.1](#).

## 6.2 Oculus Rift

Para a visualização em RV foi escolhido o Oculus Rift, que é um dos equipamentos do tipo Head Mounted Display (HMD) mais utilizados em aplicações acadêmicas e também o mais economicamente viável (XU et al., 2015). Foi utilizada neste trabalho a versão DK2 (Development Kit 2), criada em 2016 para ser usada por desenvolvedores de modo que fosse possível realizar testes e iniciar a criação de jogos antes do lançamento do produto final. O OR é composto de uma tela LCD dentro de um equipamento que é colocado na cabeça do usuário, em frente aos olhos. Dessa forma, o usuário fica completamente imerso no ambiente. A imagem é dividida em duas, uma para cada olho, que ao serem visualizadas em conjunto criam a percepção de um espaço tridimensional. O equipamento ainda possui sensores de movimento que permitem a localização do usuário no espaço físico real (NAKAGAWA; PENTEADO, 2015).

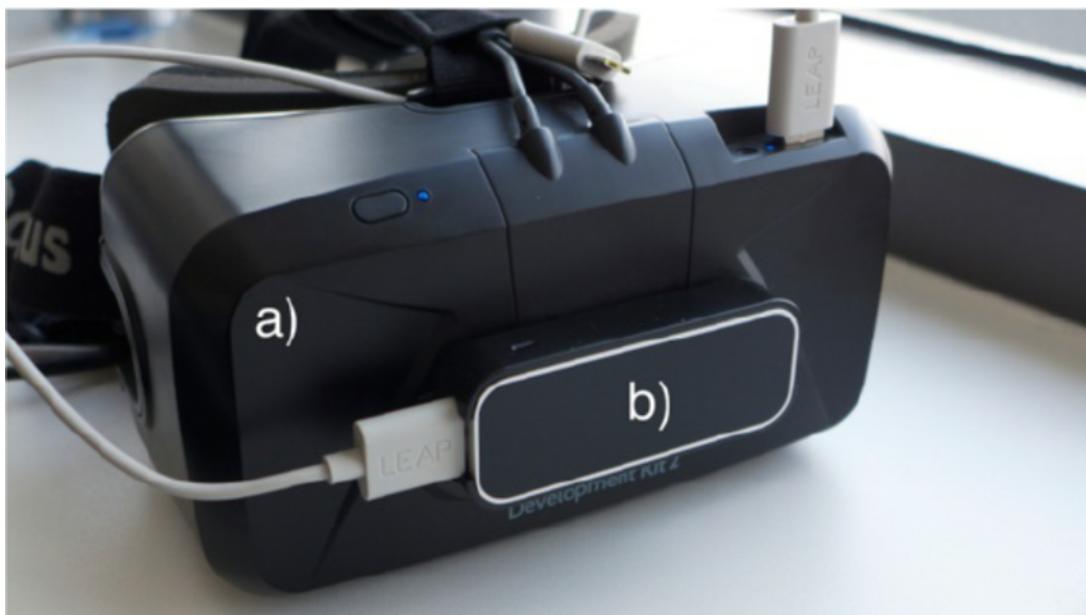
### 6.3 Leap Motion

O Leap Motion é um periférico composto por duas câmeras e três LEDs infravermelhos, que atuam em conjunto na observação de uma área hemisférica, com ângulo de  $150^\circ$  e uma distância máxima de aproximadamente um metro. Feito especialmente para o monitoramento das mãos, ele é capaz de detectar os movimentos individuais dos 10 dedos, com uma precisão de até 0,01 mm. O LM utiliza conexão USB para ser integrado a outros dispositivos, sobretudo computadores ([NAKAGAWA; PENTEADO, 2015](#)).

Os três LEDs emitem luz infravermelha sem padrão, que é refletida e capturada pelas câmeras a uma taxa de aproximadamente 200 frames por segundo. Esses dados capturados são transmitidos para o computador, onde são analisados através de algoritmos privados complexos, sintetizando a posição tridimensional a partir da análise dos frames bidimensionais produzidos ([NAKAGAWA; PENTEADO, 2015](#)).

Neste trabalho o LM foi escolhido como sensor de movimentos por permitir uma interação mais natural em RV, a partir da captura e interpretação de gestos das mãos sem a necessidade de uso de joysticks, visto que esse dispositivo pode ser acoplado a parte frontal do OR (12). Além disso, o fabricante do LM disponibiliza uma série de módulos para o seu SDK voltados para o desenvolvimento de sistemas Unity em RV, que utilizam o Oculus Rift ou outros HDM como visualizador. Essas características garantem que o LM seja compatível com os demais elementos, que em conjunto são capazes de atender os requisitos estabelecidos previamente.

Figura 12 – Oculus Rift (a) com Leap Motion (b) acoplado



Fonte: ([HILFERT; KÖNIG, 2016](#))

## 7 Implementação

Para o desenvolvimento da plataforma no Unity utilizando o LM foi utilizado o Leap Motion Orion SDK 3.2.1 em conjunto com os diferentes módulos disponibilizados online pela Leap Motion. A lista dos pacotes usados e suas respectivas versões é mostrada na tabela 7. Esse conjunto de módulos contém, entre outros recursos, os modelos utilizados para as mãos do usuário no ambiente em RV e os scripts para interação desses componentes com outros objetos.

Tabela 4 – Módulos utilizados para a implementação da plataforma

Módulo	Versão
Core Asset	4.3.4
Interaction Engine	1.1.1
Hands Module	2.1.3
Detection Examples	1.0.5

Foram criadas essencialmente três cenas: (0) cena inicial exibida quando o sistema é iniciado; (1) cena para implementação do menu principal; (2) cena para implementação dos modos de navegação.

Para realizar a transição de cena foi criado um script em C# para gerenciar a transição de cenas seguintes a partir de um índice recebido. Por exemplo, para o usuário transitar da cena 0 para a cena 1 deve fazer um sinal "thumbs up" com a mão direita, ou seja, quando o polegar direito estiver estendido, apontando para cima e os demais dedos fechados, o gerenciador recebe o valor 1 e realiza a transição (os índices das cenas se iniciam do 0 no Unity).

O script que implementa o corte transversal no modelo 3D e visualização da imagem de TC correspondente, foi implementado para responder ao movimento de uma barra deslizante do menu de opções. Assim conforme a barra é deslizada para cima ou para baixo, o corte avança na mesma direção.

# 8 Resultados

## 8.1 Segmentação

Os resultados da segmentação foram obtidos para os cinco casos da tabela 1, após a aplicação do algoritmo de segmentação descrito no capítulo 4. O modelo escolhido para utilização na plataforma foi número 5.

Este modelo tem 139 fatias, sendo cada fatia com espessura de 1,6mm e resolução espacial de 0,7819mm horizontalmente e verticalmente.

Os parâmetros obtidos pelo algoritmo de segmentação foram:

$$\mu_L = 74$$

$$\sigma_L = 19$$

$$\mu_V = 154$$

$$\sigma_V = 9$$

Os modelos reconstruídos e suavizados do fígado e dos vasos hepáticos estão contidos nas figuras 13 e 14, respectivamente.

Figura 13 – Modelo reconstruído do fígado

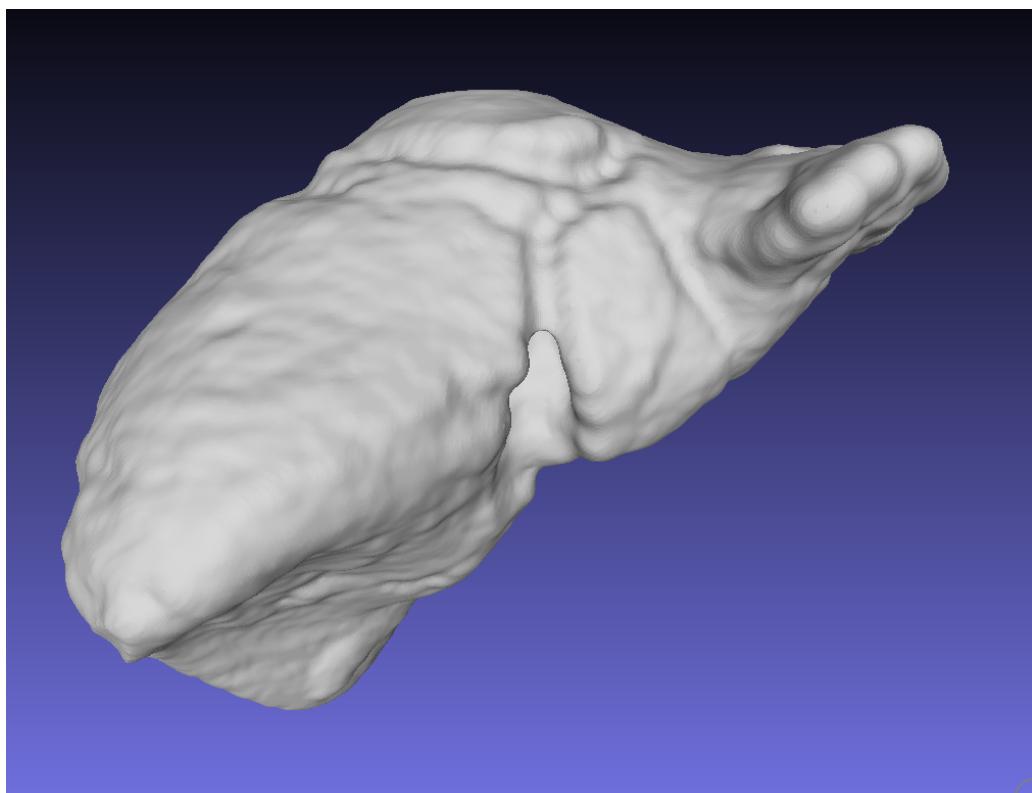


Figura 14 – Modelo reconstruído dos vasos hepáticos



A segmentação obtida pelo algoritmo foi comparada com a segmentação de referência. Esta segmentação de referência é uma segmentação feita por especialistas e ela deve retratar a verdadeira classificação do que é tecido hepático/vascular e do que não é. Métricas quantitativas podem ser calculadas comparando-se as duas segmentações. Baseado em ([TAHA; HANBURY, 2015](#)), foram escolhidas quatro métricas que avaliam propriedades de sobreposição espacial. Essas quatro métricas são: Sensitividade, Especificidade, Precisão e Índice de Jaccard.

As métricas utilizadas baseiam-se na comparação de pixels (ou voxels) de acordo com sua classificação no algoritmo ou na referência. Estes pixels podem ser separados em quatro classes distintas: Verdadeiros Positivos (VP), Falsos Positivos (FP), Verdadeiros Negativos (VN) e Falsos Negativos (FN). Os verdadeiros e falsos positivos são aqueles pixels que foram classificados corretamente em relação à referência. Os falsos positivos são aqueles classificados como pertencentes ao tecido, mas não são de acordo com a referência, e os falsos negativos são aqueles classificados como não-tecido mas, de acordo com a referência, são tecido.

As métricas são calculadas em função da contagem de pixels em cada classe. As quatro métricas podem assumir valores de 0 a 1 (ou 0% a 100%), sendo 0 correspondente

à pior segmentação possível (conforme os critérios de cada métrica) e 1 correspondente à melhor segmentação (que aconteceria caso a segmentação proposta fosse idêntica à referência). Cada métrica exprime uma característica diferente da segmentação. A sensitividade expressa a significância entre VP (o que foi classificado corretamente) e FN (o que foi ignorado pela segmentação, mas que deveria ter sido classificado). Essa métrica é útil para avaliar qual o efeito da ausência de classificação como tecido. Isso é útil principalmente onde a ausência de classificação positiva pode ser crítica (detecção de tumores). A métrica pode ser obtida a partir da equação:

$$S = \frac{VP}{VP + FN} \quad (8.1)$$

Analogamente à sensitividade, a especificidade expressa a significância entre o que foi classificado como não-tecido em relação ao que foi classificado como tecido (mas que não deveria ter sido). Como o próprio nome diz, ela exprime a especificidade da segmentação, ou seja, exprime o quanto a segmentação é capaz de classificar positivamente apenas o que deve ser classificado positivamente. A métrica calcula-se:

$$E = \frac{VN}{VN + FP} \quad (8.2)$$

As duas métricas são importantes e se complementam, pois um algoritmo que classifica todo o domínio como tecido teria uma sensitividade de 100% e um algoritmo conservativo que não classifica nada como tecido teria uma especificidade de 100% também. As duas métricas sozinhas podem levar à análises equivocadas, por isso há a importância de confrontá-las. Outra métrica útil para avaliar globalmente o quanto as falsas segmentações (positivas ou negativas) afetam nas verdadeiras é o índice de Jaccard. Este índice avalia a razão entre a intersecção da segmentação proposta e da segmentação de referência e a união delas. Portanto ele expressa quanto do que há em comum entre as duas segmentações (VP) é significativo em relação ao de que não há em comum (FP e FN). O índice pode ser calculado como:

$$J = \frac{VP}{VP + FP + FN} \quad (8.3)$$

A precisão é uma métrica que considera apenas o domínio da segmentação dada como positiva, portanto ela compara a significância dos positivos verdadeiros em relação aos falsos positivos. A métrica é útil para a compreensão de como o algoritmo de segmentação classifica equivocadamente casos como positivo, sendo similar à especificidade, mas sem levar em conta os casos negativos. A equação para precisão é:

$$P = \frac{VP}{VP + FP} \quad (8.4)$$

Essas métricas foram calculadas para cada fatia individualmente e depois a média total e o desvio padrão para cada métrica foram calculados. Na tabela 5 estão dispostos estes dados do fígado e na tabela 6 estão dispostos os dados para os vasos.

Tabela 5 – Métricas da segmentação para o fígado

	Média	Desvio Padrão	Mínimo	Máximo
Sensitividade	98,6%	1,08%	90,2%	99,94%
Especificidade	99,2%	0,6%	96,59%	100%
Índice de Jaccard	93,6%	3,7%	0%	97,53%
Precisão	94,7%	3,4%	76,43%	98,24%

Tabela 6 – Métricas da segmentação para os vasos hepáticos

	Média	Desvio Padrão	Mínimo	Máximo
Sensitividade	38,65%	25,07%	0%	85,74%
Especificidade	99,97%	0,03%	99,8%	100%
Índice de Jaccard	36,27%	24,52%	0%	76,45%
Precisão	88,88%	11,87%	12%	100%

Também foram avaliadas, tanto para a segmentação de referência, quanto para a segmentação proposta, as áreas da segmentação em cada fatia. A área em pixels de cada uma em função do número da fatia está na imagem 15 para o fígado e na imagem 16 para os vasos hepáticos.

Figura 15 – Comparação de áreas segmentadas para o fígado

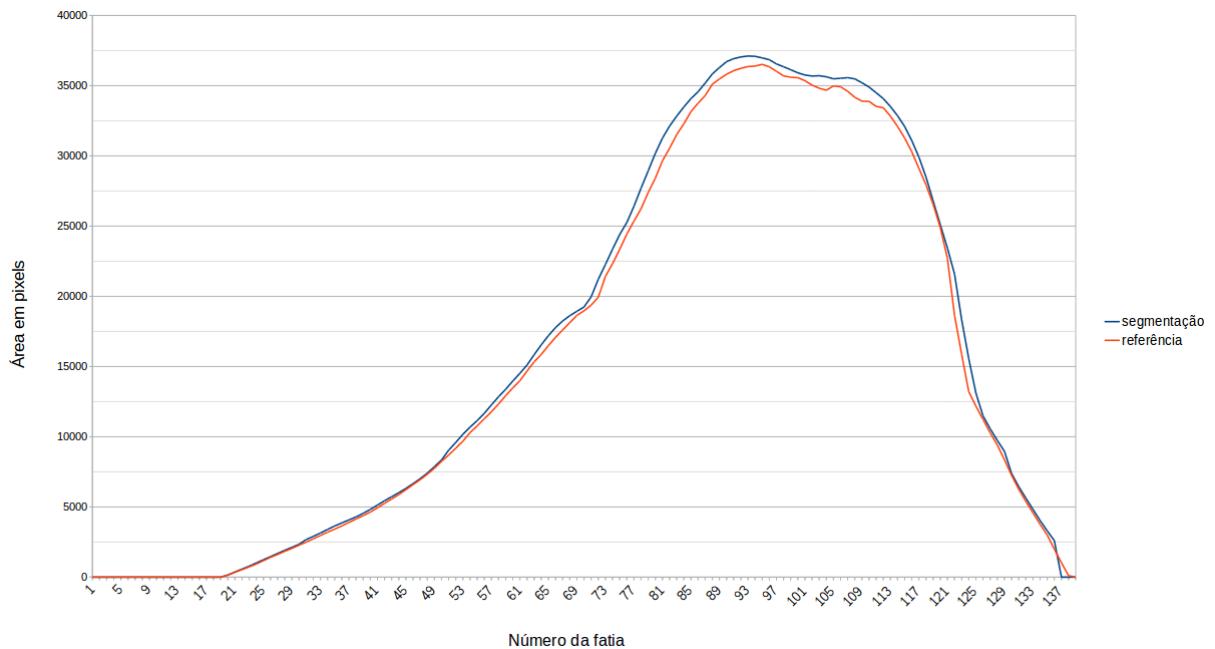
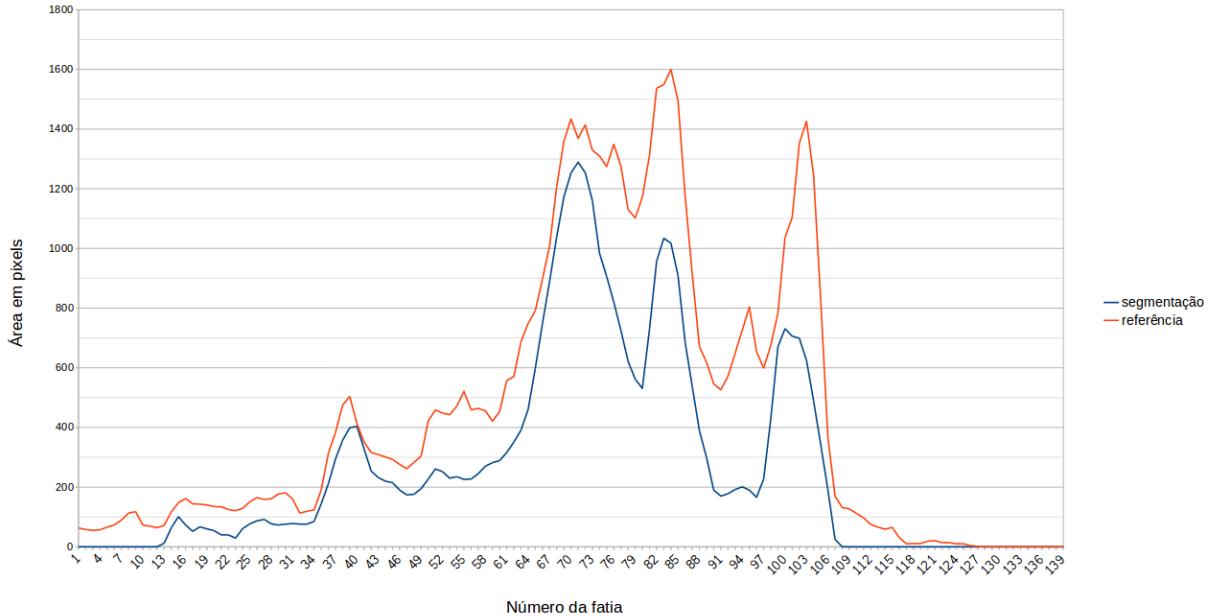


Figura 16 – Comparação de áreas segmentadas para os vasos hepáticos



Conforme a tabela 5 é possível observar que a sensitividade é alta (98,6%) e a especificidade também (99,2%), para o fígado. Portanto o algoritmo não é tão conservativo e também não excede na sua segmentação (classifica positivamente mais o que deveria). A especificidade é maior, e isto se deve ao fato de que a região classificada como sendo "não fígado" tem uma extensão muito maior. Mas este índice alto também indica que o algoritmo é pouco propenso a classificar outras regiões que não a do fígado, ou seja, mesmo que haja erros na classificação, haverá erros locais.,

O índice de Jaccard é um pouco menor mas satisfatório (93,6%), e a precisão também é satisfatória (94,7%). Analisando-se a comparação entre as áreas (figura 15), é possível ver que há um pequeno excedente constante de área da segmentação proposta em relação à segmentação de referência. Portanto é possível avaliar de modo geral que a segmentação foi satisfatória para os fins propostos.

Já a segmentação vascular tem métricas com valores menores, como por exemplo, a sensitividade e índice de Jaccard. Por outro lado a precisão (com 88,88%) e a especificidade (com 99,97%) são indícios relativamente altos, e isto indica como o algoritmo de segmentação vascular é capaz de acertar onde há presença de vasos, mas é um algoritmo conservativo, ou seja, não contempla todo o domínio real de presença dos vasos. Portanto ele é um algoritmo que contempla resultados parciais, porém esses resultados parciais seguem o volume real da segmentação verdadeira.

Em algumas seções é possível ver um aderimento melhor dos índices, já que o máximo da sensitividade é 85,74% e o máximo do índice de Jaccard é 36,27%, o que indica uma discrepância com a média e confirma que em determinadas seções a segmentação foi

mais próxima da segmentação completa. Porém os desvios padrão e os valores mínimos confirmam a diferença que existem entre diversas seções. O gráfico da figura 16 confirma a discrepância quantitativa mas nele também é possível observar como o perfil morfológico é acompanhado.

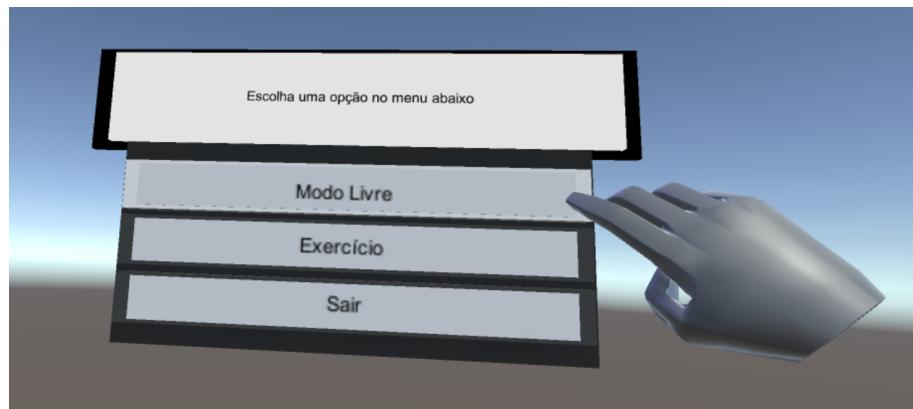
Diante deste cenário, é possível concluir que a segmentação dos vasos hepáticos é parcial e deve ser completada, porém a segmentação feita já respeita as características morfológicas do tecido e condiz com parte da estrutura anatômica.

## 8.2 Plataforma em RV

A plataforma em RV foi implementada conforme descrito no capítulo 7. Através do Unity foi então gerado o executável de uma aplicação para PC (com sistema operacional Windows) e dessa forma, o sistema é capaz de atender os requisitos de 1 a 7 da tabela 2. Essencialmente, a plataforma criada permite que:

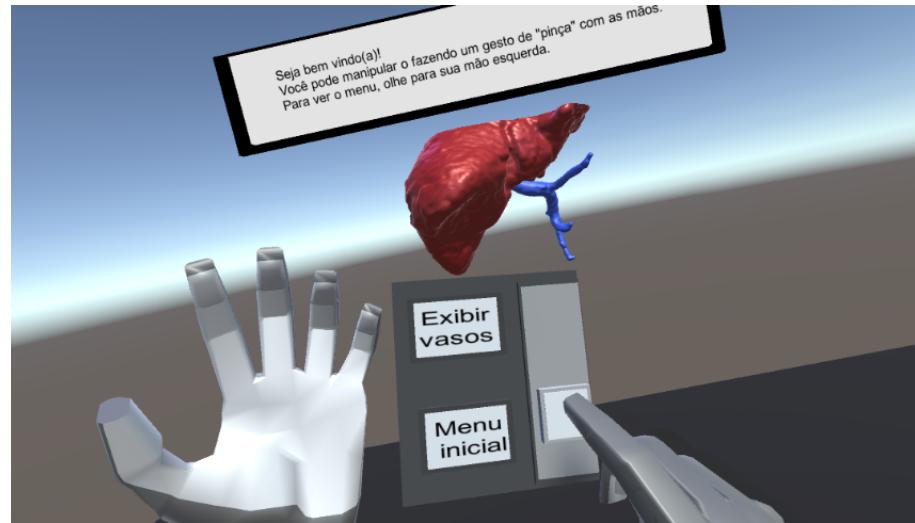
- Após a sinalização do usuário, o sistema exibe o menu inicial com as opções de navegação e encerramento do software (figura 17);

Figura 17 – Navegação pelo menu principal



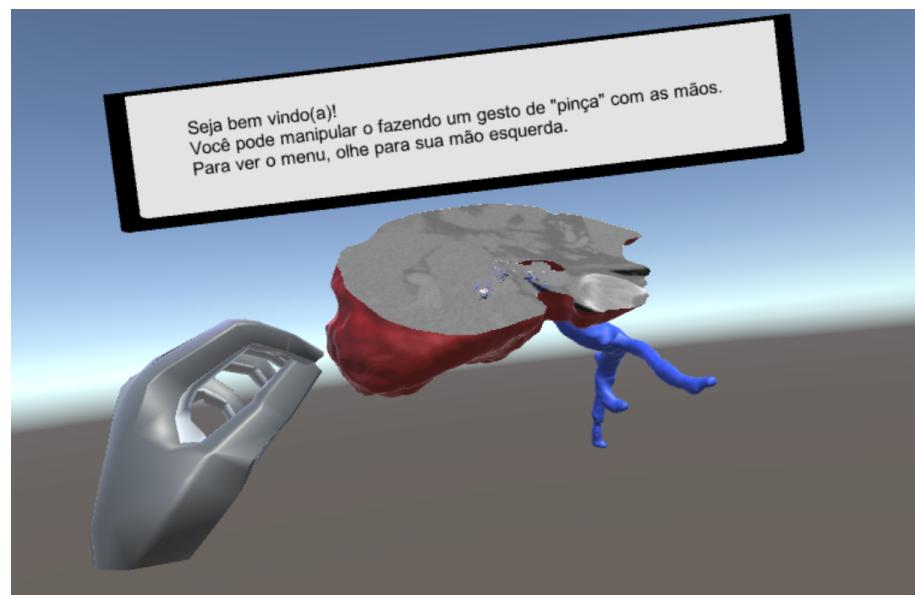
- No modo livre para exame do fígado e vasos, é possível manipular os modelos (transladar, rotacionar e redimensionar) a partir de gestos de pinça com as mãos e um menu interativo aparece sempre que o usuário olhar para a palma de sua mão esquerda (figura 18);

Figura 18 – Navegação pelo Modo Livre



- O usuário percorre todas as imagens de TC do fígado, acompanhando simultaneamente as seções correspondentes diretamente no modelo 3D (figura 19).

Figura 19 – Sobreposição da tomografia com a seção do modelo



### 8.2.1 Limitações do sistema

Para habilitar o funcionamento adequado do OR recomenda-se que o PC onde será executada a aplicação atenda ou ultrapasse as especificações mínimas contidas na tabela 8.2.1. Esse fator acaba limitando a plataforma proposta neste trabalho em termos de escalabilidade.

Tabela 7 – Especificações mínimas para uso do OR

<b>Placa gráfica</b>	NVIDIA GTX 1050 Ti/AMD Radeon RX 470 equivalente ou superior
<b>Placa gráfica alternativa</b>	NVIDIA GTX 960 4GB/AMD Radeon R9 290 ou superior
<b>CPU</b>	Intel i3-6100/AMD Ryzen 3 1200, FX4350 ou superior
<b>Memória</b>	8 GB de RAM ou mais
<b>Saída de vídeo</b>	Saída de vídeo HDMI 1.3 compatível
<b>Portas USB</b>	Uma porta USB 3.0, além de duas portas USB 2.0
<b>Sistema Operacional</b>	Windows 10 ou posterior

Fonte: ([OCULUS](#), 2018)

## 9 Conclusão

A plataforma criada para auxiliar no treinamento de residentes em cirurgia por meio de um ambiente em RV serviu para atender os requisitos funcionais estabelecidos no projeto do software. Contudo, para validá-la completamente em termos não funcionais, ainda é necessário apresentá-la ao público alvo do projeto.

O uso do LM em conjunto com o OR torna a navegação em RV intuitiva e simples. Os módulos disponíveis no SDK do Leap Motion possibilitam implementar diferentes tipos de interações muito úteis para plataformas semelhantes a deste trabalho. Os gestos e movimentos das mãos são bem identificados pelo sensor, sem que ocorram atrasos ou interpretações erradas de comandos de forma recorrente. Recomendaria-se apenas a recalibração da detecção do gesto de "pinça", visto que durante a navegação pode ocorrer eventualmente que um objeto seja movimentado sem que o usuário deseje, por conta de uma aproximação despercebida entre o polegar e os outros dedos. Isso poderia ser resolvido, por exemplo, por meio da programação de uma lógica semelhante a do reconhecimento do gesto "Thumbs up"(para entrar nesse estado, o sistema deve reconhecer que o polegar está estendido com os demais dedos fechados E o polegar aponta para cima).

As experiências ainda são limitadas a comparação entre as imagens tomográficas bidimensionais e o modelo 3D do fígado, no entanto, seria possível incluir mais funcionalidades relevantes do ponto de vista didático.

## 10 Sugestões para trabalhos futuros

Como sugestão de trabalhos futuros há o estudo da viabilidade de aplicação de plataformas como esta para o planejamento cirúrgico. Para isso seria ideal implementar a segmentação do fígado de acordo com suas regiões funcionais.

## Referências

- 3D-IRCADB-01: Banco de dados. Disponível em: <<https://www.ircad.fr/research/3d-ircadb-01/>>. Acesso em: 14 set. 2018. Citado na página 19.
- AMARO JÚNIOR, E.; YAMASHITA, H. Aspectos básicos de tomografia computadorizada e ressonância magnética. *Revista Brasileira de Psiquiatria*, SciELO Brasil, v. 23, p. 2–3, 2001. Citado na página 18.
- BEERMANN, J. et al. Three-dimensional visualisation improves understanding of surgical liver anatomy. *Medical education*, Wiley Online Library, v. 44, n. 9, p. 936–940, 2010. Citado na página 11.
- BIDGOOD JR, W. D. et al. Understanding and using DICOM, the data interchange standard for biomedical imaging. *Journal of the American Medical Informatics Association*, BMJ Group BMA House, Tavistock Square, London, WC1H 9JR, v. 4, n. 3, p. 199–212, 1997. Citado na página 18.
- BIZZOTTO, N. et al. *Leap motion gesture control with OsiriX in the operating room to control imaging: first experiences during live surgery*. [S.l.]: SAGE Publications Sage CA: Los Angeles, CA, 2014. Citado na página 12.
- CHEN, E.-L. et al. An automatic diagnostic system for ct liver image classification. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 45, n. 6, p. 783–794, 1998. Citado na página 13.
- COUINAUD, C.; DELMAS, A.; PATEL, J. Le foie: Etudes anatomiques et chirurgicales masson: Paris. 1957. Citado na página 16.
- CROSSINGHAM, J. L. et al. Interpreting three-dimensional structures from two-dimensional images: a web-based interactive 3d teaching model of surgical liver anatomy. *HPB*, Wiley Online Library, v. 11, n. 6, p. 523–528, 2009. Citado 2 vezes nas páginas 10 e 11.
- DE FREITAS, A. C. T. et al. Anatomia arterial hepática: estudo em 150 transplantes hepáticos. *Revista do Colégio Brasileiro de Cirurgiões*, Directory of Open Access Journals, v. 28, n. 1, p. 13–16, 2018. Citado na página 10.
- DOU, Q. et al. 3d deeply supervised network for automatic liver segmentation from ct volumes. In: SPRINGER. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. [S.l.], 2016. p. 149–157. Citado na página 14.
- EDINBURGH, U. of. *Connected Components Labeling*. Universidade de Edinburgh, 2018. Acesso em: 18 nov.2018. Disponível em: <<https://homepages.inf.ed.ac.uk/rbf/HIPR2/label.htm>>. Citado na página 23.
- FATTINI, C. A.; DANGELO, J. G. Anatomia humana sistêmica e segmentar. *São Paulo*: Atheneu, 2007. Citado na página 15.
- GÅSBAKK, T.; SNARBY, H. *Medical Procedural Training in Virtual Reality*. Dissertação (Mestrado) — NTNU, 2017. Citado 2 vezes nas páginas 11 e 12.

- HILFERT, T.; KÖNIG, M. Low-cost virtual reality environment for engineering and construction. *Visualization in Engineering*, Springer, v. 4, n. 1, p. 2, 2016. Citado na página 31.
- JUZA, R. M.; PAULI, E. M. Clinical and surgical anatomy of the liver: a review for clinicians. *Clinical Anatomy*, Wiley Online Library, v. 27, n. 5, p. 764–769, 2014. Citado na página 10.
- KAKINUMA, R. et al. Detection failures in spiral ct screening for lung cancer: analysis of ct findings. *Radiology*, Radiological Society of North America, v. 212, n. 1, p. 61–66, 1999. Citado na página 10.
- KÜHNAPFEL, U.; CAKMAK, H. K.; MAASS, H. Endoscopic surgery training using virtual reality and deformable tissue simulation. *Computers & graphics*, Elsevier, v. 24, n. 5, p. 671–682, 2000. Citado na página 11.
- LI, F. et al. Lung cancers missed at low-dose helical ct screening in a general population: comparison of clinical, histopathologic, and imaging findings. *Radiology*, Radiological Society of North America, v. 225, n. 3, p. 673–683, 2002. Citado na página 10.
- LORENSEN, W. E.; CLINE, H. E. Marching cubes: A high resolution 3d surface construction algorithm. In: *Proceedings of the 14th annual conference on Computer graphics and interactive techniques - SIGGRAPH '87*. ACM Press, 1987. Disponível em: <<https://doi.org/10.1145/37401.37422>>. Citado na página 26.
- MATHUR, A. S. Low cost virtual reality for medical training. In: IEEE. *Virtual Reality (VR), 2015 IEEE*. [S.I.], 2015. p. 345–346. Citado na página 12.
- NAKAGAWA, B. T.; PENTEADO, R. V. S. *Project Lambda : sistema de simulação 3D do pulmão e de suas estruturas internas por realidade virtual*. 2015. Trabalho de Formatura do curso de graduação do Departamento de Engenharia da Computação e Sistemas Digitais, EPUSP (Escola Politécnica da Universidade de São Paulo), São Paulo, Brasil. Citado 4 vezes nas páginas 12, 27, 30 e 31.
- NICOLA, S. et al. Leap motion supporting medical education. In: IEEE. *Electronics and Telecommunications (ISETC), 2016 12th IEEE International Symposium on*. [S.I.], 2016. p. 153–156. Citado na página 12.
- NUMPY: Biblioteca. Disponível em: <<http://www.numpy.org/>>. Acesso em: 11 jun. 2018. Citado na página 20.
- OCULUS: Califórnia. Especificações mínimas e recomendadas do sistema necessárias para habilitar o oculus rift. Disponível em: <<https://support.oculus.com/170128916778795/>>. Acesso em: 8 nov. 2018. Citado na página 40.
- OLIVEIRA, D. A. B. *Imagens de Tomografia Computadorizada*. Tese (Doutorado) — PUC-Rio, 2009. Citado 3 vezes nas páginas 10, 17 e 18.
- OPENCV: Biblioteca. Disponível em: <<https://opencv.org/>>. Acesso em: 11 jun. 2018. Citado na página 20.
- PYDICOM: Biblioteca. Disponível em: <<https://pydicom.github.io/>>. Acesso em: 11 jun. 2018. Citado 2 vezes nas páginas 19 e 20.

- PYTHONSTL: Biblioteca. Disponível em: <<https://python-stl.readthedocs.io/en/latest/>>. Acesso em: 11 jun. 2018. Citado na página 20.
- RIBEIRO, K. D. K. d. F. *Fígado*. Mundo Educação, 2018. Acesso em: 16 nov. 2018. Disponível em: <<https://mundoeducacao.bol.uol.com.br/biologia/figado.htm>>. Citado na página 16.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. *International Conference on Medical image computing and computer-assisted intervention*. [S.l.], 2015. p. 234–241. Citado na página 13.
- ROTH, H. R. et al. Deep convolutional networks for pancreas segmentation in ct imaging. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Medical Imaging 2015: Image Processing*. [S.l.], 2015. v. 9413, p. 94131G. Citado na página 13.
- SCIPY: Biblioteca. Disponível em: <<https://www.scipy.org/>>. Acesso em: 11 jun. 2018. Citado na página 20.
- SEIF, M. A.; UMEDA, R.; HIGA, H. An attempt to control a 3d object in medical training system using leap motion. In: IEEE. *Intelligent Informatics and Biomedical Sciences (ICIIBMS), 2017 International Conference on*. [S.l.], 2017. p. 159–162. Citado na página 12.
- SEYMOUR, N. E. et al. Virtual reality training improves operating room performance: results of a randomized, double-blinded study. *Annals of surgery*, Lippincott, Williams, and Wilkins, v. 236, n. 4, p. 458, 2002. Citado na página 11.
- SHARMA, N.; AGGARWAL, L. M. Automated medical image segmentation techniques. *Journal of medical physics/Association of Medical Physicists of India*, Wolters Kluwer-Medknow Publications, v. 35, n. 1, p. 3, 2010. Citado na página 12.
- STEFANIDIS, D. et al. Simulation in surgery: what's needed next? *Annals of surgery*, LWW, v. 261, n. 5, p. 846–853, 2015. Citado na página 12.
- STOECKER, C. et al. Determination of lung segments in computed tomography images using the euclidean distance to the pulmonary artery. *Medical physics*, Wiley Online Library, v. 40, n. 9, 2013. Citado na página 13.
- TAHA, A. A.; HANBURY, A. Metrics for evaluating 3d medical image segmentation: analysis, selection, and tool. *BMC Medical Imaging*, Springer Nature, v. 15, n. 1, aug 2015. Disponível em: <<https://doi.org/10.1186/s12880-015-0068-x>>. Citado na página 34.
- TRIVIÑO, T.; ABIB, S. d. C. V. Anatomia cirúrgica do fígado. *Acta Cirúrgica Brasileira*, SciELO Brasil, 2003. Citado 2 vezes nas páginas 15 e 16.
- UNITY 2018.1. *Unity Technologies*. 2018. <<https://unity3d.com/pt/get-unity/download/archive>>. Citado na página 30.
- UNIVERSITY, A. *Morphological Image Processing*. Universidade de Auckland, 2018. Acesso em: 18 nov. 2018. Disponível em: <<https://www.cs.auckland.ac.nz/courses/compsci773s1c/lectures/ImageProcessing-html/topic4.htm>>. Citado na página 22.

XU, C.; PHAM, D. L.; PRINCE, J. L. Image segmentation using deformable models. *Handbook of medical imaging*, Bellingham, WA: SPIE, v. 2, p. 129–174, 2000. Citado na página [13](#).

XU, X. et al. The accuracy of the oculus rift virtual reality head-mounted display during cervical spine mobility measurement. *Journal of biomechanics*, Elsevier, v. 48, n. 4, p. 721–724, 2015. Citado na página [30](#).