



HOSPITAL DE CLÍNICAS DE PORTO ALEGRE  
PROGRAMA DE RESIDÊNCIA MÉDICA EM CIRURGIA DO APARELHO DIGESTIVO

CELINA PEREIRA HALLAL

CONSTRUÇÃO DE UM MODELO DE SEGMENTAÇÃO DE IMAGEM HEPÁTICA  
UTILIZANDO INTELIGÊNCIA ARTIFICIAL - UM ESTUDO DE VIABILIDADE

Porto Alegre

2023

CELINA PEREIRA HALLAL

CONSTRUÇÃO DE UM MODELO DE SEGMENTAÇÃO DE IMAGEM HEPÁTICA  
UTILIZANDO INTELIGÊNCIA ARTIFICIAL - UM ESTUDO DE VIABILIDADE

Trabalho de Conclusão de Residência apresentado ao Programa de Residência do Hospital de Clínicas de Porto Alegre como requisito parcial para a obtenção do título de especialista em Cirurgia do Aparelho Digestivo.

Orientador(a): Professor Cleber Rosto Pinto Kruel

Porto Alegre

2023

## CIP - Catalogação na Publicação

Hallal, Celina Pereira

CONSTRUÇÃO DE UM MODELO DE SEGMENTAÇÃO DE IMAGEM  
HEPÁTICA UTILIZANDO INTELIGÊNCIA ARTIFICIAL - UM  
ESTUDO DE VIABILIDADE / Celina Pereira Hallal. --  
2023.

26 f.

Orientador: Cleber Rosito Pinto KrueI.

Trabalho de conclusão de curso (Especialização) --  
Universidade Federal do Rio Grande do Sul, Hospital de  
Clínicas de Porto Alegre, Residência Médica em Cirurgi  
do Aparelho Digestivo, Porto Alegre, BR-RS, 2023.

1. Diagnóstico assistido por computador. 2.  
Cirurgia hepática. 3. Segmentação hepática. I. KrueI,  
Cleber Rosito Pinto, orient. II. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UFRGS com os  
dados fornecidos pelo(a) autor(a).

## RESUMO

O desenvolvimento de técnicas de análise de imagens assistida por computador teve grande crescimento nas últimas décadas. A segmentação de imagens é um processo fundamental na análise computacional de exames radiológicos; ela consiste no delineamento de estruturas ou objetos, definindo regiões de interesse para uma variedade de tarefas, como classificação, registro e análise quantitativa. O presente trabalho tem como motivador a importância da segmentação hepática em cirurgia hepática, onde o conhecimento preciso do volume do fígado, do tumor e do fígado remanescente é crucial para o planejamento cirúrgico. Seu objetivo é avaliar a viabilidade da construção de um modelo de segmentação hepática em exames de tomografia computadorizada (TC), utilizando ferramentas de código aberto. Os métodos empregados envolveram segmentações manuais e semi-automáticas em exames de TC e ressonância magnética (RNM), seguido pelo desenvolvimento de um modelo totalmente automático de segmentação de exames de TC. Foram utilizados softwares e frameworks gratuitos e de código aberto, como o 3d Slicer e o MONAI Core. O modelo foi treinado utilizando dados do Medical Segmentation Decathlon, alcançando acurácia próxima de 70%. Apesar das limitações computacionais enfrentadas, este estudo demonstra a viabilidade de construir modelos de segmentação de imagem utilizando recursos de código aberto, pavimentando o caminho para experimentações na área.

Palavras-Chave: Diagnóstico auxiliado por computador, cirurgia hepática, segmentação hepática.

## ABSTRACT

The development of computer-assisted image analysis techniques has grown dramatically in recent decades. Image segmentation is a fundamental process in the computational analysis of radiological exams; it consists of delineating structures or objects, defining regions of interest for a variety of tasks, such as classification, registration and quantitative analysis. This work is motivated by the importance of liver segmentation in liver surgery, where precise knowledge of the volume of the liver, the tumor and the remaining liver is crucial for surgical planning. The aim of this study is to assess the feasibility of building a liver segmentation model in computed tomography (CT) scans, using open source tools. The methods employed involved manual and semi-automatic segmentation in CT and magnetic resonance imaging (MRI) scans, followed by the development of a fully automatic model for segmenting CT scans. Free and open source software and frameworks were used, such as 3d Slicer and MONAI Core. The model was trained using data from the Medical Segmentation Decathlon, achieving an accuracy of close to 70%. Despite the computational limitations faced, this study demonstrates the feasibility of building image segmentation models using open source resources, paving the way for further experimentation in the area.

Keywords: computer-assisted diagnosis, liver surgery, liver segmentation.

## LISTA DE ILUSTRAÇÕES

Figura 1 .....	16
Figura 2 .....	17
Figura 3 .....	18
Figura 4 .....	19
Figura 5 .....	20
Figura 6 .....	21
Figura 7 .....	22
Gráfico 1 .....	22

## **LISTA DE ABREVIATURAS E SIGLAS**

CNN	Convolutional Neural Network
FLR	Future liver remnant
IA	Inteligência Artificial
PET	Tomografia por emissão de prótons
RNM	Ressonância Nuclear Magnética
TC	Tomografia computadorizada

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>8</b>
1.1 JUSTIFICATIVA .....	9
1.2 OBJETIVOS .....	10
1.2.1 Objetivo geral.....	10
1.2.2 Objetivos específicos .....	10
<b>2 MÉTODOS .....</b>	<b>11</b>
<b>3 REVISÃO DA LITERATURA .....</b>	<b>13</b>
<b>4 RESULTADOS E DISCUSSÃO .....</b>	<b>15</b>
<b>5 CONSIDERAÇÕES FINAIS.....</b>	<b>23</b>



## 1 INTRODUÇÃO

A radiologia desempenha um papel fundamental no diagnóstico, planejamento do tratamento e acompanhamento das mais diversas doenças, oferecendo percepções inestimáveis sobre os aspectos estruturais e funcionais do corpo humano saudável e enfermo. A interpretação de imagens ainda é realizada de forma predominante por radiologistas; no entanto, nas últimas três décadas, diversas técnicas de análise de imagens auxiliada por computador vêm sendo desenvolvidas.

O processamento e análise computacional de exames radiológicos possui diversas etapas, visando traduzir os pixels e voxels em informações relevantes para a prática médica. Dentre estas etapas, sobressai-se a segmentação, que consiste no processo de delineamento das estruturas ou objetos de uma imagem, definindo assim, uma ou mais regiões de interesse. Diversas outras tarefas em análise computacional de imagens dependem dessa etapa, incluindo classificação, registro e análise quantitativa. A segmentação também fornece informações geométricas (como volume e superfície) e espaciais (disposição tridimensional de estruturas); tais informações desempenham papel importante na avaliação e planejamento terapêutico de algumas patologias.

No âmbito da cirurgia hepática, por exemplo, é necessário conhecer o volume do órgão, do tumor e do remanescente hepático futuro para o planejamento de um procedimento cirúrgico. Estes valores são obtidos através do delineamento do fígado em exame de imagem, habitualmente a tomografia computadorizada. A segmentação ainda permite a renderização tridimensional do exame de imagem, o que auxilia no planejamento de procedimentos complexos e na localização precisa de lesões neoplásicas. Além disso, a análise radiológica quantitativa, denominada radiômica, pode fornecer informações importantes acerca do comportamento de algumas doenças, e é uma área que vem despertando crescente interesse na academia.

A segmentação pode ser realizada de forma manual (contornando a estrutura ou valendo-se das diferentes densidades radiológicas), automática (sem interação do operador) ou semi-automática (demandando alguma interação com o exame). A grande vantagem dos modelos automáticos e semi-automáticos é diminuir substancialmente o tempo necessário para a realização da tarefa.

## 1.1 JUSTIFICATIVA

A segmentação de imagem é processo fundamental em qualquer tarefa de análise computacional de imagens radiológicas. É possível treinar modelos de aprendizagem de máquina para diversas tarefas, tais como identificar a presença de dada patologia, caracterizar fenótipos radiológicos e entender aspectos prognósticos de uma doença. Para qualquer que seja o objetivo, é necessário segmentar a imagem, ou seja, definir a região de interesse a ser estudada - o órgão, o tecido, o tumor.

Em cirurgia hepática, a segmentação fornece informações definidoras do tratamento, e é rotineiramente realizada no planejamento de hepatectomias. No entanto, se realizada de maneira manual, é uma tarefa laboriosa e tempo-intensiva, além de estar sujeita à variabilidade inter-operador. O desenvolvimento de modelos automáticos e semi-automáticos de segmentação busca reduzir a dificuldade da tarefa e o tempo necessário para a sua realização, além de aumentar a reprodutibilidade do método

## 1.2 OBJETIVOS

### 1.2.1 Objetivo geral

O presente trabalho tem por objetivo avaliar a viabilidade da construção de um modelo automático de segmentação hepática em exames de tomografia computadorizada.

### 1.2.2 Objetivos específicos

- Gerar modelo de inteligência artificial capaz de delinear o fígado em exame tomográfico sem nenhuma interação humana, utilizando para tal apenas ferramentas de código aberto.
- Avaliar a viabilidade de adaptar o modelo para outras tarefas de segmentação de imagem em radiologia.

## 2 MÉTODOS

Para a presente exploração, foram utilizados softwares e frameworks gratuitos e de código aberto. Na primeira fase, realizaram-se segmentações manuais e semi-automáticas de exames de TC e RNM. Num segundo momento, desenvolveu-se modelo totalmente automático de segmentação de exames de TC.

A plataforma 3d Slicer (FEDOROV et al., 2012) teve papel nas segmentações manuais exploratórias, no teste de alguns modelos disponíveis e na visualização dos modelos tridimensionais. Ademais, foram utilizados alguns frameworks disponíveis na plataforma, a citar:

- SlicerBatchAnonymize para a remoção de qualquer metadado relacionado a pacientes (HINA-SHAH, 2023);
- Elastix para o registro das imagens baseado em intensidade (GILLIES; KINAHAN; HRICAK, 2016);
- Vesselness Modeling ToolKit - VMTK (ANTIGA et al., 2008);
- Clara NVIDIA AI (“ANR R-Vessel-X Project · GitHub”, [s.d.]);
- R-Vessel-X (“ANR R-Vessel-X Project · GitHub”, [s.d.]), e Slicer Liver (“ALive-research/Slicer-Liver”, [s.d.]) para reconstrução semi-automática.

Foram realizadas reconstruções tridimensionais do volume hepático, do(s) tumor(es) e dos vasos arteriais, portais, e venosos, bem como do FLR estimado, em exames de TC e RNM.

Para o modelo automático, utilizou-se o framework MONAI Core (CARDOSO et al., 2022). O código foi escrito em python e rodado na nuvem no serviço Google Colaboratory (“colab.google”, [s.d.]). Foram utilizados os dados do Medical Segmentation Decathlon, especificamente os contidos na Task03\_Liver (ANTONELLI et al., 2022; “Medical Segmentation Decathlon”, [s.d.]). Este é um dataset público com exames de imagem reais segmentados por radiologistas e disponibilizado com o intuito de realizar processos de segmentação por aprendizado de máquina.

O dataset em questão consiste em 201 exames de tomografia provenientes dos IRCAD Hôpitaux Universitaires, sendo 131 exames segmentados e 70 exames não-segmentados. Para este projeto foram utilizados apenas os dados previamente segmentados,

para permitir a comparação entre o desempenho do modelo e a segmentação do radiologista. Optou-se por realizar o treinamento com metade do dataset, com os casos escolhidos de forma aleatória, devido à limitação computacional. Dividiu-se em 48 exames para treinamento e 14 exame para teste (22,5% da amostra). As imagens foram pré-processadas para otimizar o treinamento do algoritmo e realizou-se um processo típico de treinamento de aprendizado de máquina. A arquitetura de rede neural escolhida para o treinamento foi U-Net (RONNEBERGER; FISCHER; BROX, 2015) com 5 layers. Como métricas utilizadas escolheu-se o Dice Coefficient e Dice loss (SUDRE et al., 2017); ambas são funções complementares que medem a sobreposição entre a segmentação esperada e a segmentação predita pelo modelo. Um dice coefficient de 0 significa que não há sobreposição entre as imagens, enquanto um dice coefficient de 1 representa a sobreposição absoluta entre a imagem esperada e a imagem predita pelo modelo. A dedução matemática das métricas foge do escopo deste trabalho.

### 3 REVISÃO DA LITERATURA

Diversas áreas da medicina utilizam informações visuais para o diagnóstico e tratamento de patologias. Alguns exemplos incluem a radiologia, a dermatologia, a patologia, a endoscopia, a cardiologia e a cirurgia (LIDSTRÖMER; ARESU; ASHRAFIAN, 2022). Desde a década de 90, tem-se explorado a utilização de algoritmos de aprendizado de máquina nas mais diversas aplicações, nestas áreas e em inúmeras outras (BAXT, 1995, DYBOWSKI, 2020).

Uma grande quantidade de dados radiológicos é produzida na atualidade, e exames de imagem são um dos principais pilares no diagnóstico e tratamento da imensa maioria das patologias (PHAM; XU; PRINCE, 2000). Diversos métodos computacionais vêm sendo desenvolvidos com o intuito de auxiliar nas mais variadas fases e tarefas de processamento e análise de imagens. Algumas das tarefas-chave incluem:

- Classificação: separa as imagem em categorias pré-definidas, por exemplo, presença ou não de uma alteração, graduação de uma patologia (SHARMA et al., 2008);
- Segmentação: é o delineamento de uma região de interesse, que pode ser um órgão, uma estrutura, uma lesão tumoral, um tecido (PHAM; XU; PRINCE, 2000);
- Registro: é a regularização geométrica entre duas ou mais imagens para uma comparação mais precisa; pode ser realizada entre exames de métodos distintos (TC, PET, RNM) (MAINTZ; VIERGEVER, 1998);
- Análise quantitativa: chamada de radiômica, é a extração e análise de diversos dados quantificáveis em uma imagem, que podem fornecer informações diagnósticos e prognósticas da patologia estudada (GILLIES; KINAHAN; HRICAK, 2016).

Em todos os outros processos a segmentação tem parte, na identificação da região a ser classificada, registrada ou analisada quantitativamente. Ela também fornece informações como o volume e a superfície da estrutura delineada. Múltiplas técnicas de aprendizado de máquina já foram descritas para a segmentação de exames de imagem (GUL et al., 2022). No que tange à cirurgia hepática, estas informações são imprescindíveis no planejamento peri-operatório; o volume remanescente futuro (Future liver remnant ou FLR) é um dos principais determinantes na indicação da cirurgia e no risco de complicações, e sua medida acurada pela volumetria tem papel fundamental nessa avaliação (RIBERO et al., 2013).

Além das informações fornecidas pela volumetria, a segmentação da imagem permite a renderização em 3 dimensões. A visualização tridimensional permite um melhor planejamento cirúrgico (TAKAMOTO et al., 2022, WANG et al., 2017) e auxilia no ensino e compreensão de conceitos anatômicos complexos (PUJOL et al., 2016). Ademais, tais modelos podem ser integrados ao campo cirúrgico por meio de realidade aumentada, permitindo a navegação intra-operatória (KINGHAM et al., 2012). Métodos computacionais complementares podem simular o fluxo sanguíneo no órgão, permitindo ainda mais precisão no planejamento de procedimentos complexos (ANTÓN et al., 2021; MISE et al., 2011; WHITE et al., 2016).


## 4 RESULTADOS E DISCUSSÃO

Foram realizadas segmentações manuais e semi-automáticas de 6 exames. (Figuras 1 a 6). O exame 1 é uma segmentação realizada exclusivamente usando método automático com o algoritmo Clara Nvidia. O exame 2 é uma segmentação manual de exame tomográfico. O exame 3 inclui o registro de imagem de exames com métodos distintos (TC e RNM). O exame 4 inclui o registro de duas imagens de tomografia em momentos distintos do tratamento. O exame 5 é uma segmentação de variação anatômica de via biliar. O exame 6 é uma reconstrução multivisceral. O objetivo destas segmentações foi demonstrar a versatilidade de utilizações do método no planejamento pré-operatório e explorar diversos métodos de segmentação. No entanto, as segmentações manuais são extremamente laboriosas, tempo intensivas, sujeitas a vieses do executor e pouco reproduzíveis, mas se realizadas por operador com experiência, proporcionam clara visualização tridimensional da patologia a ser estudada, auxiliando no planejamento peri-operatório.

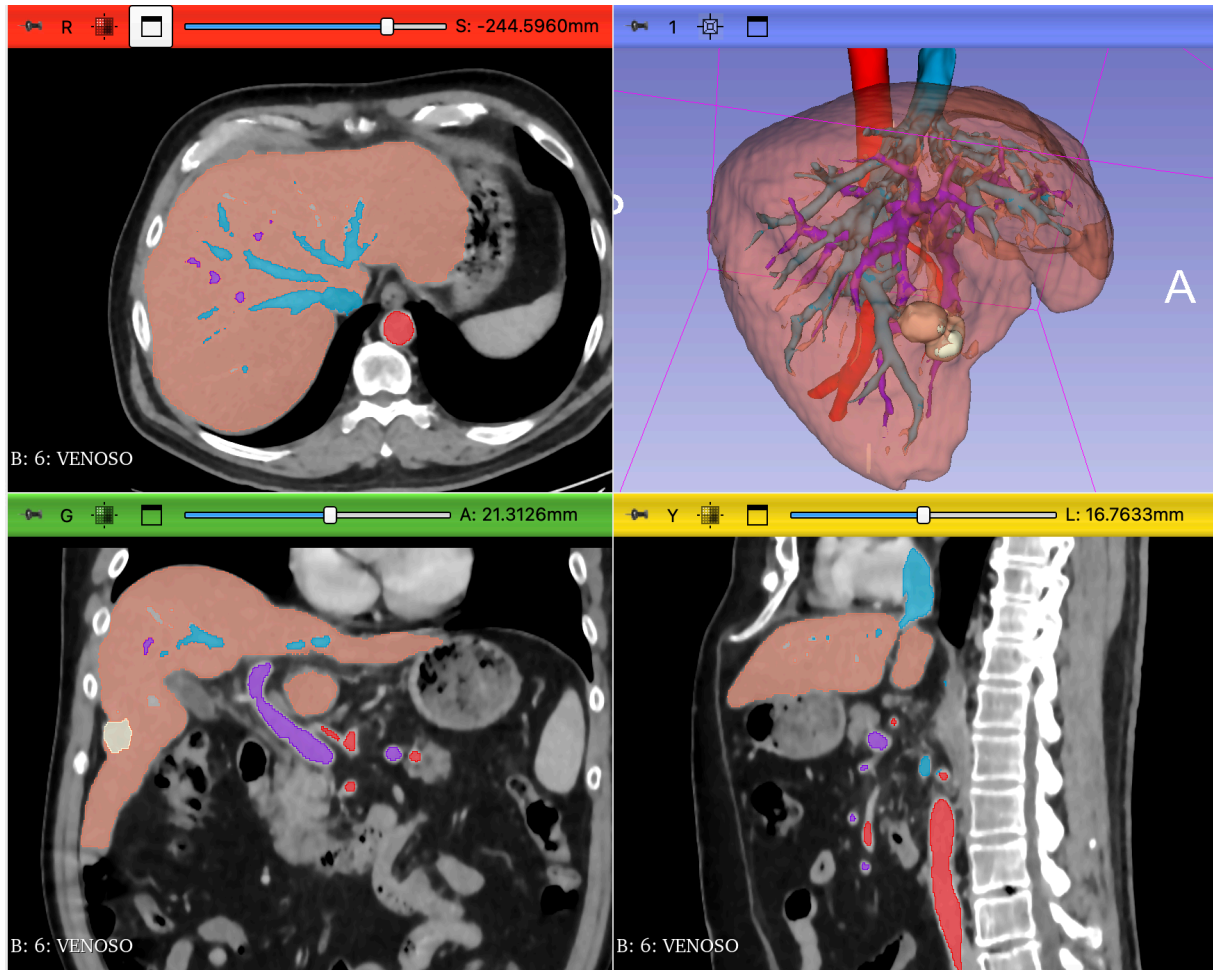
O modelo de rede neural convolucional previamente descrito foi treinado por 250 épocas. Em aprendizado de máquina, cada época é a passagem do algoritmo por todos os dados de treinamento, sua aplicação nos dados de teste e o ajuste nos seus parâmetros. Analisa-se um algoritmo de IA avaliando sua capacidade de generalizar o aprendizado para dados previamente desconhecidos (dados de teste). O modelo atingiu sua melhor performance na época 119, com dice coefficient de 0.68 (gráfico 1, imagem 7). Optou-se por avaliar a performance utilizando dice coefficient/dice loss como métricas devido ao desbalanço entre o tamanho da imagem total e a área segmentada. O modelo é rudimentar, mas pode-se observar que é capaz de prever razoavelmente bem a imagem que representa o fígado.

A presente exploração foi importantemente limitada pela capacidade computacional disponível, o que limitou a quantidade de dados de treinamento do modelo. Tais experimentos demandam máquinas com grande capacidade computacional, de custo elevado e disponibilidade restrita. No entanto, demonstra a viabilidade de construir um algoritmo de segmentação de imagem apenas com recursos de código aberto, e pavimentando o caminho para o desenvolvimento de trabalhos futuros.







**Figura 1.** Segmentação e reconstrução automática do fígado utilizando algoritmo publicamente disponível (Clara NVIDIA AI). Observa-se a imprecisão do modelo, que identifica o baço como parte constituinte do fígado e não delinea adequadamente a metade inferior do órgão.




**Figura 2.** Segmentação e reconstrução manual por contorno e intensidade do fígado, vasculatura correspondente e tumor hepático. A maior precisão ocorre às custas de um maior tempo para segmentação do exame.




**Figura 5.** Reconstrução a partir de colangiorressonância magnética de alteração anatômica de via biliar, com identificação de cisto de colédoco (rosa), junção panúreatobiliar anômala (amarelo) e ducto biliar com drenagem para o infundíbulo da vesícula (azul).



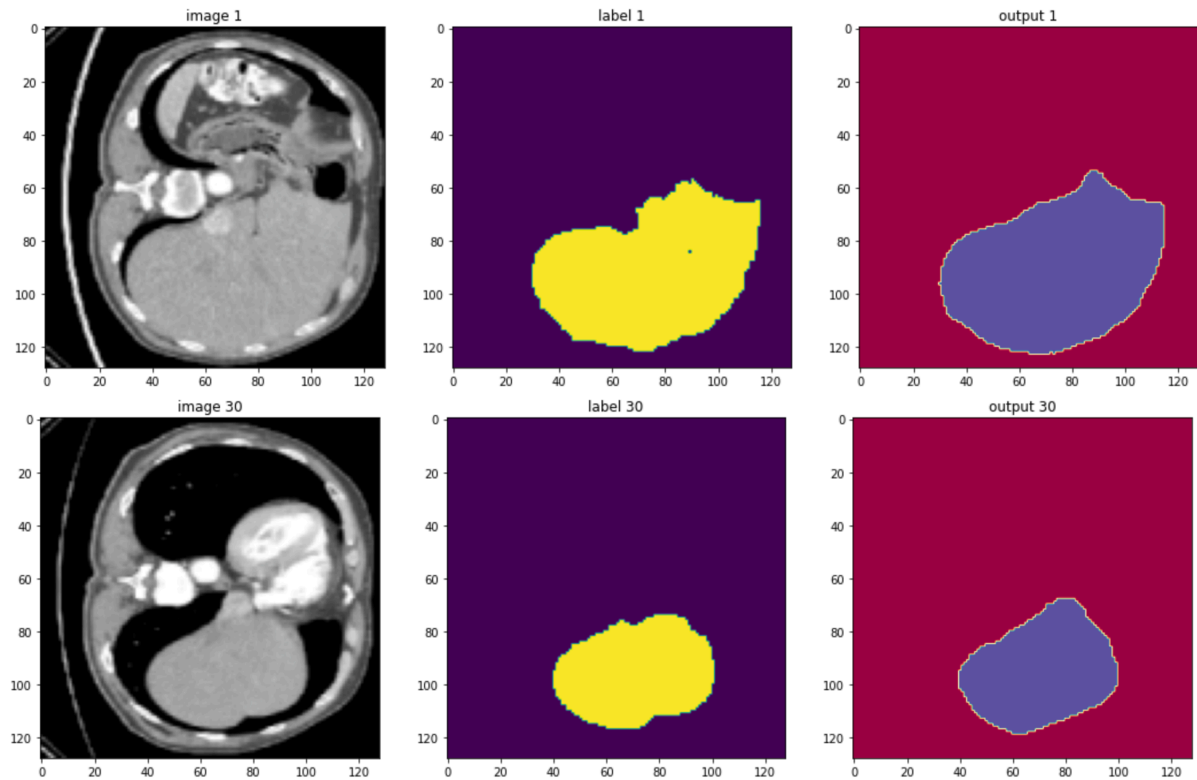
**Figura 3.** Reconstrução de imagem após fusão de exame de tomografia e ressonância magnética (lesões coloridas). Neste caso, a fusão entre modalidades distintas permitiu a melhor identificação das numerosas lesões neoplasias.



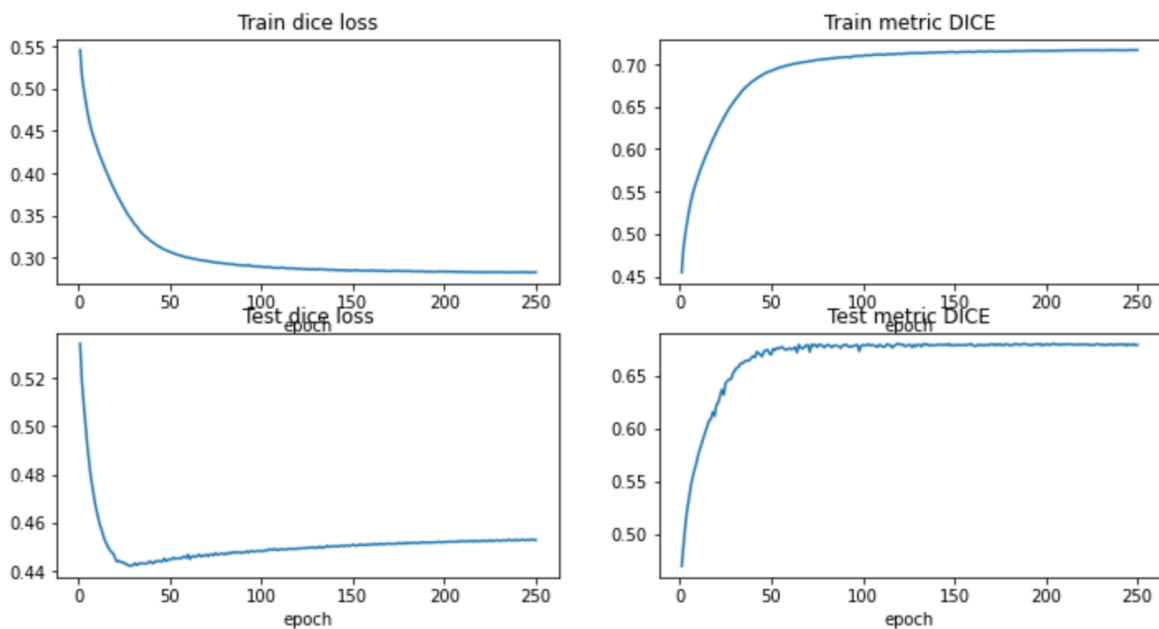
**Figura 4.** Reconstrução de imagem após fusão de exames em dois momentos distintos do tratamento, permitindo a comparação acurada do tamanho das lesões neoplasias antes (amarelo) e depois (branco, visto por transparência) do tratamento.



**Figura 6.** Reconstrução abdominal multivisceral para melhor visualização de lesão tumoral invasiva comprometendo pâncreas, estômago, baço e cólon; Associa-se presença de variações anatômicas no duodeno e cólon, nesta imagem vistos em transparência.



**Figura 7.** Imagem radiológica, segmentação verdadeira e segmentação gerada pelo modelo de inteligência artificial, respectivamente



**Gráfico 1.** Performance de treinamento (superior) e de teste (inferior) do modelo de inteligência artificial

## 5 CONSIDERAÇÕES FINAIS

Inteligência artificial e aprendizado de máquinas são temas ubíquos na mídia, no dia-a-dia e na academia. Suas aplicações na área da saúde vêm sendo exploradas na literatura, mas ainda há um imenso potencial a ser explorado, nas mais diversas especialidades médicas. Fica claro na literatura que este tema tende a ser cada vez mais presente na medicina, seja em âmbito acadêmico, seja na prática médica.

O presente estudo não se propõe a ser uma exploração exaustiva do tema, mas uma análise introdutória de segmentação de imagens médicas, com o objetivo de desenvolver o método ulteriormente para outras aplicações. Conquanto seja limitado em comparação a métodos mais complexos disponíveis na literatura, demonstra-se a viabilidade da segmentação de imagens radiológicas com ferramentas disponíveis on-line e com código aberto. Tal experimentação busca abrir caminhos para a construção de modelos mais complexos de segmentação, e posteriormente, análise computacional de imagens radiológicas.



## REFERÊNCIAS

**ALive-research/Slicer-Liver**. ALive. Disponível em: <<https://github.com/ALive-research/Slicer-Liver>>. Acesso em: 22 jan. 2023.

**ANR R-Vessel-X Project · GitHub**. Disponível em: <<https://github.com/R-Vessel-X>>. Acesso em: 21 jan. 2023.

ANTIGA, L. et al. An image-based modeling framework for patient-specific computational hemodynamics. **Medical & Biological Engineering & Computing**, v. 46, n. 11, p. 1097, nov. 2008.

ANTÓN, R. et al. A proof-of-concept study of the in-vivo validation of a computational fluid dynamics model of personalized radioembolization. **Scientific Reports**, v. 11, n. 1, p. 3895, 16 fev. 2021.

ANTONELLI, M. et al. The Medical Segmentation Decathlon. **Nature Communications**, v. 13, n. 1, p. 4128, 15 jul. 2022.

BAXT, W. G. Application of artificial neural networks to clinical medicine. **The Lancet**, v. 346, n. 8983, p. 1135–1138, out. 1995.

CARDOSO, M. J. et al. **MONAI: An open-source framework for deep learning in healthcare**. arXiv, , 4 nov. 2022. Disponível em: <<http://arxiv.org/abs/2211.02701>>. Acesso em: 10 jan. 2023.

**colab.google**. Disponível em: <<http://0.0.0.0:8080/>>. Acesso em: 10 jan. 2023.

DIAZ-PINTO, A. et al. **MONAI Label: A framework for AI-assisted Interactive Labeling of 3D Medical Images**. arXiv, , 23 mar. 2022. Disponível em: <<http://arxiv.org/abs/2203.12362>>. Acesso em: 21 jan. 2023.

DYBOWSKI, R. Emergence of Deep Machine Learning in Medicine. Em: LIDSTRÖMER, N.; ASHRAFIAN, H. (Eds.). **Artificial Intelligence in Medicine**. Cham: Springer International Publishing, 2020. p. 1–9.

ELNAKIB, A. et al. Medical Image Segmentation: A Brief Survey. Em: EL-BAZ, A. S. et al. (Eds.). **Multi Modality State-of-the-Art Medical Image Segmentation and Registration Methodologies**. New York, NY: Springer New York, 2011. p. 1–39.

FEDOROV, A. et al. 3D Slicer as an Image Computing Platform for the Quantitative Imaging Network. **Magnetic resonance imaging**, v. 30, n. 9, p. 1323–1341, nov. 2012.

GAVRIILIDIS, P. et al. Navigated liver surgery: State of the art and future perspectives. **Hepatobiliary & Pancreatic Diseases International**, v. 21, n. 3, p. 226–233, jun. 2022.  
GILLIES, R. J.; KINAHAN, P. E.; HRICAK, H. Radiomics: Images Are More than Pictures, They Are Data. **Radiology**, v. 278, n. 2, p. 563–577, fev. 2016.

GUL, S. et al. Deep learning techniques for liver and liver tumor segmentation: A review. **Computers in Biology and Medicine**, v. 147, p. 105620, ago. 2022.

HINA-SHAH. **hina-shah/SlicerBatchAnonymize**. , 23 fev. 2023. Disponível em: <<https://github.com/hina-shah/SlicerBatchAnonymize>>. Acesso em: 11 jan. 2023.

KINGHAM, T. P. et al. Image-guided liver surgery: intraoperative projection of computed tomography images utilizing tracked ultrasound. **HPB**, v. 14, n. 9, p. 594–603, set. 2012.

KLEIN, S. et al. elastix: A Toolbox for Intensity-Based Medical Image Registration. **IEEE Transactions on Medical Imaging**, v. 29, n. 1, p. 196–205, jan. 2010.

LIDSTRÖMER, N.; ARESU, F.; ASHRAFIAN, H. Introductory Approaches for Applying Artificial Intelligence in Clinical Medicine. Em: LIDSTRÖMER, N.; ASHRAFIAN, H. (Eds.). **Artificial Intelligence in Medicine**. Cham: Springer International Publishing, 2022. p. 57–74.

MAINTZ, J. B. A.; VIERGEVER, M. A. A survey of medical image registration. **Medical Image Analysis**, v. 2, n. 1, p. 1–36, 1 mar. 1998.

**Medical Segmentation Decathlon**. Disponível em: <<http://medicaldecathlon.com/>>. Acesso em: 24 jan. 2023.

MISE, Y. et al. Venous reconstruction based on virtual liver resection to avoid congestion in the liver remnant. **British Journal of Surgery**, v. 98, n. 12, p. 1742–1751, 27 out. 2011.

**NVIDIA Clara**. Disponível em: <<https://docs.nvidia.com/clara/index.html>>. Acesso em: 24 jan. 2023.

PHAM, D. L.; XU, C.; PRINCE, J. L. Current Methods in Medical Image Segmentation. **Annual Review of Biomedical Engineering**, v. 2, n. 1, p. 315–337, ago. 2000.

PUJOL, S. et al. Using 3D Modeling Techniques to Enhance Teaching of Difficult Anatomical Concepts. **Academic Radiology**, v. 23, n. 4, p. 507–516, abr. 2016.

RIBERO, D. et al. Measured versus Estimated Total Liver Volume to Preoperatively Assess the Adequacy of the Future Liver Remnant: Which Method Should We Use? **Annals of Surgery**, v. 258, n. 5, p. 801–807, nov. 2013.

RONNEBERGER, O.; FISCHER, P.; BROX, T. **U-Net: Convolutional Networks for Biomedical Image Segmentation**. arXiv, , 18 maio 2015. Disponível em: <<http://arxiv.org/abs/1505.04597>>. Acesso em: 24 jan. 2023.

SHARMA, N. et al. Segmentation and classification of medical images using texture-primitive features: Application of BAM-type artificial neural network. **Journal of Medical Physics**, v. 33, n. 3, p. 119, 2008.

SUDRE, C. H. et al. Generalised Dice overlap as a deep learning loss function for highly unbalanced segmentations. Em: **Lecture Notes in Computer Science**. v. 10553p. 240–248.

TAKAMOTO, T. et al. Automated Three-Dimensional Liver Reconstruction with Artificial Intelligence for Virtual Hepatectomy. **Journal of Gastrointestinal Surgery**, v. 26, n. 10, p. 2119–2127, out. 2022.

WANG, X.-D. et al. Traditional surgical planning of liver surgery is modified by 3D interactive quantitative surgical planning approach: a single-center experience with 305 patients. **Hepatobiliary & Pancreatic Diseases International**, v. 16, n. 3, p. 271–278, jun. 2017.

WHITE, D. et al. Building a 3D Virtual Liver: Methods for Simulating Blood Flow and Hepatic Clearance on 3D Structures. **PLOS ONE**, v. 11, n. 9, p. e0162215, 20 set. 2016.

YANG, J. et al. MedMNIST v2 - A large-scale lightweight benchmark for 2D and 3D biomedical image classification. **Nature Scientific Data**, v. 10, n. 1, p. 41, 19 jan. 2023.