

Segmentação de gorduras cardíacas utilizando uma rede generativa adversária condicional

Guilherme Santos da Silva¹, Érick Oliveira Rodrigues¹

¹Departamento de Informática – Universidade Tecnológica Federal do Paraná (UTFPR)
Caixa Postal 571 – 85503-390 – Pato Branco – PR – Brazil

guilhermesantossilva@alunos.utfpr.edu.br, erickrodrigues@utfpr.edu.br

Abstract. *In recent years, studies have shown that the increase in the amount of fat surrounding the heart was associated with a higher risk of triggering some cardiovascular diseases, such as atrial fibrillation and coronary heart disease. Manual segmentation of these fats has not been widely implemented in clinical practice due to the human workload required and the high cost of physicians and technicians. Therefore, the need to perform quantitative analysis more accurately and faster in exams with a lot of information has driven the development of new computational methods for organ segmentation. In this work, a new unified method for the autonomous segmentation and quantification of two types of cardiac fats was proposed, using the pix2pix network, a generative conditional adversary network ideally created to perform image-to-image translation. Segmented fats are called epicardium and mediastinal and are separated from each other by the pericardium. Experimental results of the proposed methodology showed that the mean accuracy in relation to epicardial and mediastinal fats is 99.08%, with a true positive mean rate of 99.34%. The similarity indices were, on average, 99.28% and 98.59%, for the F_1 score and IoU, respectively.*

Resumo. *Nos últimos anos, estudos têm apontado que o aumento da quantidade de gordura que envolve o coração foi associado a maior risco para o desencadeamento de algumas doenças cardiovasculares, como a fibrilação atrial e a doença coronariana. A segmentação manual dessas gorduras não tem sido amplamente implantada na prática clínica devido à carga de trabalho humana necessária e ao alto custo de médicos e técnicos. Portanto, a necessidade de realizar análises quantitativas de forma mais precisa e mais rápida em exames com muitas informações têm impulsionado o desenvolvimento de novos métodos computacionais para a segmentação de órgãos. Neste trabalho, foi proposto um novo método unificado para a segmentação e quantificação autônoma de dois tipos de gorduras cardíacas, utilizando a rede pix2pix, uma rede generativa adversária condicional criada idealmente para realizar a tradução de imagem para imagem. As gorduras segmentadas são denominadas epicárdio e mediastinal e ficam separadas umas das outras pelo pericárdio. Resultados experimentais da metodologia proposta mostraram que a acurácia média em relação às gorduras epicárdicas e mediastinais é de 99,08%, com uma taxa média positiva verdadeira de 99,34%. Os índices de similaridade foram, em média, de 99,28% e 98,59%, para o F_1 score e IoU, respectivamente.*

1. Introdução

A importância da imagem na medicina, facilitando a compreensão e elaboração de etapas em um diagnóstico o mais preciso possível, tem melhorado imensamente o conhecimento médico e esclarecido caminhos para uma escolha terapêutica mais adequada dos diversos quadros de doenças que um ser humano pode apresentar (GALVÃO, 2000).

Estudos têm apontado que o aumento da quantidade de gordura que envolve o coração foi associado a maior risco para o desencadeamento de algumas doenças cardiovasculares, como a fibrilação atrial e a doença coronariana. Atualmente, algumas técnicas se mostram adequadas para a quantificação desses tecidos adiposos: ressonância magnética (RM), ecocardiografia e tomografia computadorizada (TC). Embora essas modalidades tenham sido amplamente utilizadas em diversos estudos na literatura, a tomografia computadorizada fornece uma avaliação mais precisa dos tecidos adiposos devido à sua maior resolução espacial quando comparada à ultrassonografia e ressonância magnética (RODRIGUES et al., 2015b). A necessidade de realizar análises quantitativas de forma mais precisa e mais rápida em exames com muitas informações têm impulsionado o desenvolvimento de novos métodos computacionais para a segmentação de órgãos (TORRES, 2012).

A segmentação de imagens se refere ao processo de classificar cada pixel de uma imagem em uma determinada categoria, com o objetivo de simplificar e/ou mudar a representação de uma imagem para facilitar a sua análise. Portanto, ao segmentar uma imagem, processos como quantificação e identificação de objetos podem ser facilitados.

Para contribuir com a tarefa de segmentar e quantificar gorduras cardíacas, diversos trabalhos surgiram após a introdução da segmentação semântica. Rodrigues et al. (2015b) empregaram uma metodologia para segmentar automaticamente e, conseqüentemente, discriminar as gorduras epicárdicas e, pela primeira vez, gorduras mediastinais em imagens de TC cardíacas, utilizando técnicas do aprendizado de máquina clássico, como extração de características e algoritmos de classificação. Com o crescimento do aprendizado de máquina e aprendizado profundo novas possibilidades surgiram, por exemplo algoritmos com foco especificamente em segmentação de imagens e redes neurais mais sofisticadas, tal como a *U-net*, que é uma rede neural convolucional desenvolvida para segmentação biomédica de imagens, e a *pix2pix*, uma rede generativa voltada para a tarefa de tradução de imagem para imagem, sendo esta última a utilizada neste trabalho.

Ao introduzir a rede *pix2pix*, Isola et al. (2017) constataram que redes generativas adversárias condicionais (cGANs - do inglês, *Conditional Generative Adversarial Networks*) são capazes de resolver o problema de segmentação semântica com um grau razoável de precisão e embora cGANs alcancem algum sucesso, elas estão longe de ser o melhor método disponível para resolver esta tarefa. Portanto, o presente trabalho busca implementar um novo método para a tarefa de segmentação de gorduras cardíacas, utilizando a rede *pix2pix*, uma rede generativa adversária condicional criada idealmente para realizar a tradução de imagem para imagem. Busca-se avaliar o desempenho de uma arquitetura nova, poderosa e versátil em tarefas de tradução imagem-a-imagem, frente a modelos amplamente aceitos e utilizados como referência na literatura, como a rede *U-net*, avaliando e comparando posteriormente, em termos de eficácia e tempo, os resultados obtidos com o de estudos anteriores, a fim de explorar o potencial dessa nova tecnologia em tarefas de visão computacional na qual seu desempenho normalmente é inferior.

2. Trabalhos relacionados

Atualmente, existem muitos trabalhos sobre o desenvolvimento da segmentação e quantificação da gordura epicárdica, sendo este o problema do presente trabalho. Shahzad et al. (2013) propuseram o primeiro procedimento totalmente automatizado para segmentação do pericárdio e subsequente determinação do volume de gordura epicárdica em tomografias cardíacas sem contraste usando multi-atlas e métodos de limiarização.

Rodrigues et al. (2015b) propuseram a segmentação automática e a determinação de dois tipos de gorduras cardíacas em imagens de TC usando algoritmos de registro de imagem para ajustar a entrada, extração de *features* e, finalmente, classificação. Dentre algumas de suas contribuições, é importante citar a criação de uma base dados para gorduras cardíacas que está disponível online para futuros estudos e aplicações. Os estudos a seguir utilizam a mesma base, a fim de comparar os diferentes métodos e tecnologias desenvolvidos para o problema abordado neste trabalho e seus resultados, com a abordagem apresentada pelo autor.

Priya e Sudha (2019) propuseram outra abordagem para segmentação das gorduras cardíacas. O método proposto neste trabalho consiste na extração de *features* usando recursos de uma matriz de coocorrência de nível de cinza (GLCM, do inglês - *Gray Level Co-occurrence Matrix*) e o algoritmo de otimização *Fruit Fly* baseado no crescimento de região. Toda a experimentação foi implementada no ambiente de simulação MATLAB e com o objetivo de que o resultado final seja uma distinção definitiva entre as gorduras mediastinais cardíacas e epicárdicas. Este trabalho visa estimular o setor de saúde em direção a técnicas computacionais mais inteligentes que multiplicam a variedade de eficiência.

Li, Zou e Yang (2019) propuseram uma abordagem de aprendizado profundo para a segmentação do pericárdio. Foi introduzida uma estrutura piramidal de pooling para o U-Net e aprimorado o processo de treinamento para torná-lo melhor na segmentação do pericárdio. Para analisar seu desempenho com precisão, ele é testado separadamente em termos de gorduras mediastinais e epicárdicas.

Kazemi et al. (2020) propuseram um método que inclui a etapa de pré-processamento usando limiar na faixa de gordura e aumento de contraste usando análise de histograma, etapa de extração de *feature* com base em *features* de textura extraídos usando o banco de filtros Gabor com base na GLCM e informações de pixel, e a etapa de segmentação de gorduras cardíacas é baseada em rotulagem de pixel e algoritmos de classificação de reconhecimento de padrão.

Zhang et al. (2020) propuseram um novo método para segmentação automática e quantificação da gordura epicárdica a partir de tomografias computadorizadas com precisão. Em detalhe, U-Nets duplas com a camada de processamento morfológico são usadas para este objetivo.

O estudo realizado por Albuquerque et al. (2020), emprega um algoritmo de agrupamento denominado *Floor of Log* (FoL). A vantagem desse método é a queda significativa no tempo de segmentação. Support Vector Machine foi usado para aprender o melhor parâmetro do algoritmo FoL, bem como técnicas de morfologia matemática para remoção de ruído. O tempo para segmentar a gordura cardíaca em uma TC é de apenas 2,01 segundos em média. Em contraste, os trabalhos da literatura requerem mais de uma hora para

realizar a segmentação. Portanto, este trabalho é um dos mais rápidos para segmentar completamente um exame.

3. Pix2pix

Pix2pix é uma rede adversária condicional generativa proposta por Isola et al. (2017) que aprende um mapeamento de imagens de entrada para imagens de saída. Esta rede não tem uma aplicação específica - pode ser aplicada a uma ampla gama de tarefas, incluindo sintetizar fotos de mapas de etiquetas, gerar fotos coloridas a partir de imagens em preto e branco, transformar fotos do *Google Maps* em imagens aéreas, transformar esboços em fotos e realizar segmentação semântica (Figura 1), que é o foco do presente trabalho.

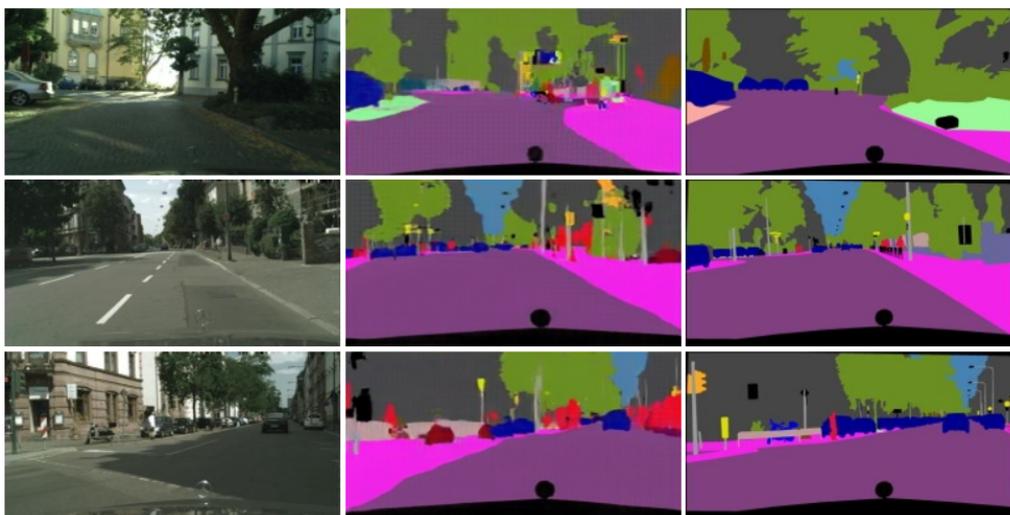


Figura 1. Resultados de exemplo em um problema de segmentação semântica utilizando *pix2pix*.

4. Metodologia

Diferentes experimentos foram realizados com o intuito de compreender o impacto de cada método utilizado nos resultados obtidos. De modo geral, todos os experimentos seguem o mesmo fluxo de processos.

4.1. Aquisição da base de dados

Segundo Rodrigues et al. (2015b), a tomografia computadorizada possui duas vantagens importantes sobre as radiografias convencionais: reconstruções de imagens tridimensionais e a capacidade de quantificar a atenuação de raios-X. A atenuação é expressa em TC através da escala de unidade Hounsfield (HU, do inglês - *Hounsfield Unit*). Os feixes de raios-X usados para radiologia diagnóstica são compostos por fótons com um amplo espectro de energias. Cada sistema e fabricante incorpora uma combinação única de fonte de raios-X, matriz de detectores e geometria de projeção. Portanto, ao tentar segmentar informações armazenadas no HU, essas variações devem ser devidamente contabilizadas.

Para acessar adequadamente o tecido adiposo cardíaco nas tomografias, precisamos considerar um intervalo em torno de -100 HU, que, por sua vez, corresponde à gordura total do corpo humano, conforme apresentado na Tabela 1. Neste trabalho, será

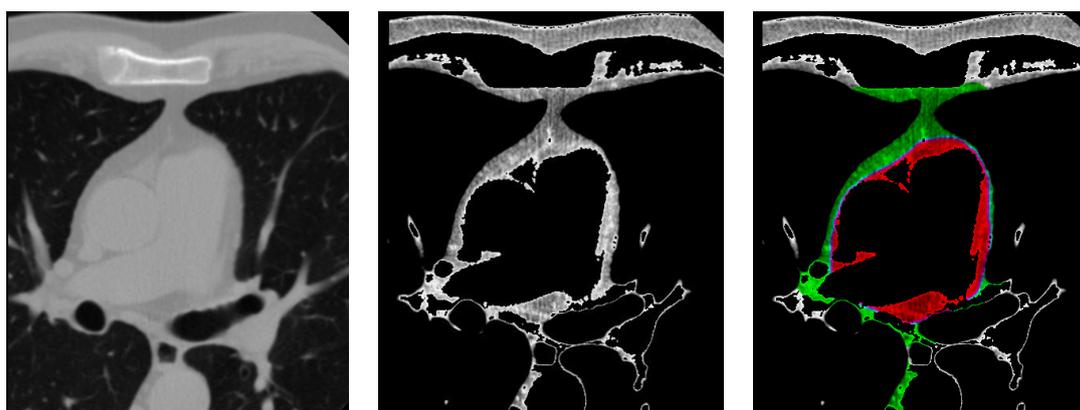
utilizada a base de imagens disponível em Rodrigues et al. (2015a), que abrange um intervalo de -200 HU a -30 HU. Este intervalo escolhido engloba a faixa de HU referente ao tecido adiposo, se encaixa adequadamente em uma imagem de 8 bits de profundidade e nenhuma interpolação é necessária, evitando qualquer possível perda de dados.

Tabela 1. Escala Hounsfield

Substância	HU
Ar	-1000
Pulmão	-500
Gordura	-100 a -50
Água	0
Fluido cerebrospinal	15
Rim	30
Sangue	30 a 45
Músculo	10 a 40
Massa cinzenta	37 a 45
Massa branca	20 a 30
Fígado	40 a 60
Tecidos moles, Contraste	100 a 300
Osso	700 a 3000

A Figura 2 ilustra à esquerda uma imagem de tomografia computadorizada de um coração, dentro do intervalo de -1000 a 720 HU, englobando tecidos, fluidos, ar e gorduras, todos registrados pela TC, enquanto a central ilustra a mesma imagem dentro somente do intervalo de -200 a -30 HU. Esta mesma imagem servirá como entrada do modelo de segmentação e a da direita representa o *ground truth*.

Figura 2. Imagem de TC com intervalo de -1000 a 720 HU (esquerda), imagem de TC com intervalo de -200 a 30 HU (centro) e *ground truth* (direita).



As imagens foram segmentadas manualmente por um médico e um cientista da computação e consistem em uma segmentação das gorduras epicárdicas e mediastinais em tomografias computadorizadas cardíacas sem contraste, totalizando 843 imagens. A cor vermelha representa a gordura epicárdica, a cor verde representa a gordura mediastinal e a cor azul representa a lacuna entre as gorduras epicárdica e mediastinal, que também pode ser interpretada como pericárdio (RODRIGUES et al., 2015a).

5. Treinamento

Para os experimentos a seguir, as imagens foram ordenadas de forma randômica a fim de garantir maior diversidade ao treinamento e consequentemente, um melhor resultado. Por recomendação de Isola et al. (2017), o banco de dados foi separado através do método *3-way holdout*, que consiste em três *sets*, um de treino, um de validação e um de teste, conforme a Tabela 2. Esta abordagem pode ser empregada para encontrar e otimizar o melhor modelo (ZIAEE, 2020), para redução de *overfitting* e ajuste fino de hiperparâmetros.

Tabela 2. Alocação das imagens em *datasets* para treinamento.

<i>Dataset</i>	Quantidade de imagens	Tamanho (em pixels)
Treinamento	562	512 x 512
Validação	169	512 x 512
Teste	112	512 x 512

A seleção do melhor modelo de segmentação se dá através da variação de hiperparâmetros, como a variação da taxa de aprendizagem, número de épocas e *batch size*. Durante o treinamento, existem processos que podem ser realizados, como por exemplo inverter uma imagem horizontalmente ou redimensioná-la para um tamanho maior e depois para seu tamanho original (parâmetros *"flip"* e *"resize and crop"*, respectivamente), com o propósito de gerar mais dados para o treino, sendo este o método de *data augmentation*, em que a ideia é aumentar a quantidade e a diversidade dos dados do seu *dataset*.

6. Medidas de avaliação

Em problemas de classificação, existem medidas específicas relacionadas à predição: VP (Verdadeiro Positivo), VN (Verdadeiro Negativo), FP (Falso positivo) e FN (Falso Negativo). Para o problema em questão, VP é o pixel de gordura gerado corretamente no mapa de segmentação, VN é o pixel de fundo gerado corretamente, FP é o pixel de fundo gerado incorretamente para pixel de gordura, FN é o pixel de gordura gerado incorretamente como pixel de fundo ou como outro tipo de gordura (POPESCU et al., 2021). Após o cálculo dessas medidas, é possível encontrar a taxa de verdadeiros positivos, ou seja, o percentual de pixels de gordura gerados corretamente, e a taxa de falsos positivos, que representa o percentual de pixels de fundo gerados como pixels de gordura.

Apesar de válidas como medidas de desempenho, em alguns casos as medidas citadas anteriormente não demonstram de fato a eficiência da segmentação. Resumidamente, quando as classes são extremamente desequilibradas, isso significa que uma classe ou algumas classes dominam a imagem, enquanto algumas outras classes constituem apenas uma pequena parte da imagem. Neste caso, é possível perceber que grande parte da imagem é composta por pixels de fundo. Assim, é possível que as medidas descritas anteriormente apresentem resultados ótimos se a segmentação for excelente para os pixels de fundo, mas totalmente falha quanto aos pixels de gordura.

Dessa forma, para lidar com esta questão, será calculado o F_1 -score e o IoU, que são medidas que representam a similaridade entre dois conjuntos de dados como um único valor entre 0 e 1, e podem ser expressas também em termos de VP, FP e FN, como apresentado nas Equações 1 e 2. Essas medidas são comumente usada para quantificar o desempenho dos métodos de segmentação de imagem.

$$F_1 = \frac{2 \times VP}{2 \times VP + FP + FN} \quad (1)$$

$$IoU = \frac{VP}{VP + FP + FN} \quad (2)$$

7. Análise e discussão dos resultados

Dentre os experimentos produzidos, o primeiro experimento, com redimensionamento da imagem de entrada, apresentou os melhores resultados, alcançando uma acurácia média de 99,08%, taxa de verdadeiros positivos média (pixels gerados corretamente) de 99,34% e F_1 *score* médio de 99,28%, corroborando para o uso desta rede para tarefas de segmentação. Outra vantagem desta abordagem é o tempo levado para realizar a segmentação das gorduras cardíacas, sendo este de 1,44 segundos por imagem, aproximadamente, que possibilita o uso futuro desta abordagem no dia a dia dos profissionais de medicina.

O segundo experimento, com somente uma gordura, apresentou resultados inferiores ao primeiro experimento e uma redução em sua eficácia ao ter realizado pós-processamentos morfológicos nas primeiras imagens geradas. É possível notar que a operação morfológica de fechamento eliminou os pequenos "buracos" presente nas imagens, porém gerou pequenos ruídos nestas, aumentando o seu erro em relação ao *ground truth*. Uma possível solução que pode trazer melhoras em trabalhos futuros, seria a implementação de um algoritmo de redução de ruídos, como um filtro de média, por exemplo, em que o valor de um pixel é substituído por uma mediana dos níveis de intensidade na vizinhança desse pixel.

Para o terceiro e quarto experimentos, com tamanho original e divisão da imagem de entrada, respectivamente, uma possível solução pode ser a redução dos dados para treinamento e teste, a fim a acurácia e taxa de acertos. Um dos parâmetros que podem ser alterados para compor outra solução é o *batch size*. O *batch size* define o número de amostras que serão propagadas pela rede em cada iteração e o *batch size* da *pix2pix* é, por padrão, 1, ou seja, a rede seleciona uma imagem por vez ao realizar o treinamento. Aumentando o *batch size* para 4, por exemplo, seriam selecionadas 4 amostras do *dataset* (em sequência ou não) e agrupadas. Com um grande volume de dados, esta abordagem pode trazer melhoras significantes para estas abordagens. As Tabelas 3 e 4 comparam os resultados obtidos entre os experimentos realizados.

Para realizar a comparação dos resultados obtidos neste trabalho com outros presentes na literatura, foram utilizados os melhores valores de cada estudo. É importante salientar que a forma mais coerente e justa de realizar tal comparação entre as abordagens adotadas, seria com a utilização do mesmo ambiente de execução e mesmos parâmetros de treinamento, desde a divisão do *dataset* até aos parâmetros utilizados nos experimentos que alcançaram tais resultados. A Tabela 5 denota esta comparação. O método proposto figura entre os melhores métodos para segmentação de gorduras cardíacas, considerando os trabalhos citados, perdendo somente para o estudo de Kazemi et al. (2020), em termos de acurácia da gordura epicárdica e mediastinal, e para o estudo de Priya e Sudha (2019), em termos de acurácia da gordura mediastinal.

Tabela 3. Comparação dos resultados obtidos nos experimentos realizados para gordura epicárdica.

Gordura epicárdica						
Experimento	Acc %	TVP %	TVN %	F₁ %	IoU %	Tempo por imagem (s)
Com redimensionamento	98,90	99,26	98,18	99,14	98,31	01,44
Com uma gordura (sem pós-processamento)	98,68	99,41	97,21	98,93	97,90	01,49
Com uma gordura (com pós-processamento)	98,63	99,47	97,00	98,90	97,83	01,78
Com tamanho original da imagem de entrada	99,21	99,55	98,42	99,42	98,86	03,28
Com imagem de entrada dividida	98,45	99,15	97,37	98,45	96,95	01,74

Tabela 4. Comparação dos resultados obtidos nos experimentos realizados para gordura mediastinal.

Gordura mediastinal						
Experimento	Acc %	TVP %	TVN %	F₁ %	IoU %	Tempo por imagem (s)
Com redimensionamento	98,97	99,23	98,36	99,22	98,46	01,44
Com uma gordura (sem pós-processamento)	—	—	—	—	—	—
Com uma gordura (com pós-processamento)	—	—	—	—	—	—
Com tamanho original da imagem de entrada	98,12	99,07	95,91	98,67	97,38	03,28
Com imagem de entrada dividida	96,39	97,63	94,19	96,83	93,83	01,74

8. Conclusão

Neste trabalho, foi proposto um método para segmentar a gordura do coração de imagens de tomografia computadorizada utilizando pela primeira vez, conforme a literatura revisada até o momento, a rede *pix2pix*, uma rede generativa adversária condicional. A base de dados utilizada nos experimentos é pública, disponível em Rodrigues et al. (2015a), e adaptações foram necessárias para esta base ser utilizada pela *pix2pix*. Diversos experimentos foram realizados a fim de explorar a versatilidade desta nova tecnologia e encontrar formas de potencializar seu desempenho em tarefas de segmentação semântica, envolvendo pré-processamentos e pós-processamentos diferentes, adequados a cada tipo de situação experimental.

Dentre os experimentos realizados, o que obteve os melhores resultados foi com redimensionamento da imagem de entrada, evidenciando que a *pix2pix* apresenta um desempenho excelente com os parâmetros definidos como padrão. Os métodos propostos

Tabela 5. Comparação dos resultados da segmentação de gorduras cardíacas de trabalhos prévios.

Trabalho	Classe	Acurácia (%)	F ₁ (%)	Tempo (segundos)
Shahzad et al. (2013)	Epicárdica	–	89,15	–
Rodrigues et al. (2015b)		98,50	98,10	156
Machine... (2017)		98,76	98,71	–
Priya e Sudha (2019)		–	–	–
Li, Zou e Yang (2019)		99,50	97,80	–
Kazemi et al. (2020)		–	91,19 ± 1,41	–
Zhang et al. (2020)		93,45	–	02,01
Albuquerque et al. (2020)		98,90	99,14	01,44
Método proposto				
Shahzad et al. (2013)	Mediastinal	–	–	–
Rodrigues et al. (2015b)		98,40	–	156
Priya e Sudha (2019)		99,23	98,26	–
Li, Zou e Yang (2019)		–	–	–
Kazemi et al. (2020)		99,40	–	–
Zhang et al. (2020)		–	91,19 ± 1,41	–
Albuquerque et al. (2020)		93,45	–	02,01
Método proposto		98,97	99,22	01,44
Shahzad et al. (2013)	Pericárdio	–	–	–
Rodrigues et al. (2015b)		96,40	–	156
Priya e Sudha (2019)		98,20	98,52	–
Li, Zou e Yang (2019)		–	–	–
Kazemi et al. (2020)		98,90	98,40	–
Zhang et al. (2020)		–	91,19 ± 1,41	–
Albuquerque et al. (2020)		93,45	–	02,01
Método proposto		99,36	99,49	01,44

alcançaram resultados que figuram entre os melhores encontrados na literatura, mostrando que estes podem integrar sistemas de auxílio ao diagnóstico médico para a segmentação da gordura cardíaca a partir de imagens de tomografia computadorizada do coração, considerando o tempo necessário para segmentação e sua qualidade. Em conclusão, os resultados alcançados são muito satisfatórios. Ainda há melhoras e abordagens diferentes a serem realizadas para aumentar a eficácia da *pix2pix* neste problema de segmentação. Contudo, a metodologia proposta pode ser adaptada a outras modalidades de imagem com um esforço menor.

Referências

ALBUQUERQUE, V. H. C. de et al. Fast fully automatic heart fat segmentation in computed tomography datasets. **Computerized Medical Imaging and Graphics**, v. 80, p. 101674, 2020. ISSN 0895-6111. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0895611119300898>.

GALVÃO, P. B. d. A. Tecnologia e medicina: imagens médicas e a relação médico-

paciente. **Revista Biomédica**, v. 8, 2000. Disponível em: https://revistabioetica.cfm.org.br/index.php/revista/_bioetica/article/view/267/267.

ISOLA, P. et al. Image-to-image translation with conditional adversarial networks. **CoRR**, 2017. Disponível em: <http://arxiv.org/abs/1611.07004>.

KAZEMI, A. et al. Automated segmentation of cardiac fats based on extraction of textual features from non-contrast ct images. In: **2020 25th International Computer Conference, Computer Society of Iran (CSICC)**. [S.l.: s.n.], 2020. p. 1–7.

LI, Z.; ZOU, L.; YANG, R. A neural network-based method for automatic pericardium segmentation. In: **Proceedings of the 2nd International Conference on Computer Science and Software Engineering**. New York, NY, USA: Association for Computing Machinery, 2019. (CSSE 2019), p. 45–49. Disponível em: <https://doi.org/10.1145/3339363.3339372>.

MACHINE learning in the prediction of cardiac epicardial and mediastinal fat volumes. **Computers in Biology and Medicine**, v. 89, p. 520–529, 2017. ISSN 0010-4825.

POPESCU, D. et al. Retinal blood vessel segmentation using pix2pix gan. In: **2021 29th Mediterranean Conference on Control and Automation (MED)**. [S.l.: s.n.], 2021. p. 1173–1178.

PRIYA, C.; SUDHA, S. Adaptive fruitfly based modified region growing algorithm for cardiac fat segmentation using optimal neural network. **Journal of Medical Systems**, v. 43, p. 1–13, 2019.

RODRIGUES, et al. **Cardiac Fat Database - Computed Tomography**. 2015. Disponível em: <http://visual.ic.uff.br/en/cardio/ctfat/>. Acesso em: 17 de agosto de 2021.

RODRIGUES, et al. A novel approach for the automated segmentation and volume quantification of cardiac fats on computed tomography. **Computer Methods and Programs in Biomedicine**, v. 123, p. 109–128, 2015. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0169260715002448>.

SHAHZAD, R. et al. Automatic quantification of epicardial fat volume on non-enhanced cardiac ct scans using a multi-atlas segmentation approach. **Medical Physics**, v. 40, n. 9, 2013. Disponível em: <https://aapm.onlinelibrary.wiley.com/doi/abs/10.1118/1.4817577>.

TORRES, A. S. A. **Segmentação de Imagens Médicas Visando a Construção de Modelos Médicos**. Dissertação (Mestrado em Tecnologia Biomédica) — Escola Superior de Tecnologia e Gestão, Instituto Politécnico de Bragança, Bragança, 2012.

ZHANG, Q. et al. Automatic epicardial fat segmentation and quantification of ct scans using dual u-nets with a morphological processing layer. **IEEE Access**, v. 8, p. 128032–128041, 2020.

ZIAEE, A. **Pix2Pix-for-Semantic-Segmentation-of-Satellite-Images**. 2020. Disponível em: <https://github.com/A2Amir/Pix2Pix-for-Semantic-Segmentation-of-Satellite-Images>. Acesso em: 17 de agosto de 2021.