

Segmentação de Artérias Coronárias em Imagens de Angiografia por Tomografia Computadorizada Utilizando Redes Neurais Convolucionais 3D[☆]

3D Convolutional Neural Network-Based Segmentation of Coronary Arteries in Computed Tomography Angiography Images

Esbel Tomas Valero Orellana^{1,2,†}, Marcelo Ossamu Honda^{1,2}, Paulo Eduardo Ambrósio^{1,2}, Cleviton Borges de Jesus², Allan de Medeiros Martins², Dany Sanchez Dominguez^{1,2}

¹Universidade Estadual de Santa Cruz, Campus Soane Nazaré de Andrade - Ilhéus, BA, Brazil

²Centro de Pesquisa e Desenvolvimento Tecnológico em Informática e Eletroeletrônica de Ilhéus - Ilhéus, BA, Brazil

[†]**Autor correspondente:** evalero@uesc.br

Resumo

A doença arterial coronariana (DAC) é a principal causa de morte por doenças cardiovasculares no mundo. A avaliação precisa do risco de DAC é crucial para a prevenção. A angiografia por tomografia computadorizada (ATC) é um método não invasivo amplamente utilizado para diagnosticar a DAC. A segmentação precisa das artérias coronárias nas imagens de ATC é fundamental para quantificar a doença e auxiliar no diagnóstico. Neste estudo, avaliamos um conjunto de imagens de ATC disponibilizado pelo projeto ImageCAS e comparamos diferentes algoritmos de segmentação, incluindo um método de segmentação direta proposto. Avaliamos o desempenho dos algoritmos utilizando o índice de *dice score*, comparando os resultados com um padrão de referência (*ground truth*). Experimentamos diferentes resoluções de imagem para analisar o impacto no desempenho e no consumo de recursos computacionais. Além disso, propomos um método de ensemble para combinar os resultados de diferentes algoritmos, visando melhorar a precisão da segmentação. Os resultados obtidos demonstram que o método de ensemble proposto alcança um desempenho superior em comparação com os algoritmos individuais.

Palavras-chave

Artéria coronária • Segmentação • Aprendizado profundo • Auxílio ao diagnóstico • Imagens médicas

Abstract

Coronary Artery Disease (CAD) is the leading cause of death from cardiovascular diseases worldwide. Accurate risk assessment of CAD is crucial for prevention. Computed Tomography Angiography (CTA) is a widely used non-invasive method for diagnosing CAD. Accurate segmentation of coronary arteries in CTA images is essential for quantifying the disease and aiding in diagnosis. In this study, we evaluated a dataset of CTA images provided by the ImageCAS project and compared different segmentation algorithms, including a proposed direct segmentation method. We evaluated the performance of the algorithms using the Dice similarity coefficient, comparing the results to a ground truth. We experimented with different image resolutions to analyze the impact on performance and computational resource consumption. Additionally, we propose an ensemble method to combine the results of different algorithms, aiming to improve segmentation accuracy. The obtained results demonstrate that the proposed ensemble method achieves superior performance compared to individual algorithms.

[☆]Este artigo é uma versão estendida do trabalho apresentado no XXVII ENMC Encontro Nacional de Modelagem Computacional e XV ECTM Encontro de Ciência e Tecnologia de Materiais, ocorridos em Ilhéus – BA, de 1 a 4 de outubro de 2024.

Keywords

Coronary artery • Segmentation • Deep learning • Computer-aided diagnostic • Medical images

1 Introdução

As doenças cardiovasculares constituem a principal causa de morte natural em todo o mundo, com cerca de 20,5 milhões de óbitos registrados em 2021 [1]. Dentre essas, a doença arterial coronariana (DAC) destaca-se como a mais prevalente, afetando aproximadamente 6% da população adulta. A obstrução total dos vasos sanguíneos, frequentemente associada à DAC, pode levar a complicações graves e até mesmo à morte [2].

Considerando a gravidade das doenças cardiovasculares e o alto índice de mortalidade, o diagnóstico precoce e o tratamento adequado da DAC são cruciais. A DAC é caracterizada pelo estreitamento (estenose) das artérias coronárias, comprometendo o fluxo sanguíneo para o coração [2].

A angiografia por tomografia computadorizada (ATC) é um método não invasivo amplamente utilizado para diagnosticar a DAC [3]. A ATC permite a visualização tridimensional das artérias coronárias, fornecendo informações detalhadas sobre a anatomia e a presença de estenoses. Com base nestas imagens é possível realizar a segmentação das artérias, ou seja identificar aqueles boxels que, por possuir características semelhantes, podem ser identificados como pertencentes à artéria. A segmentação das artérias coronárias nas imagens de ATC é fundamental para quantificar a doença e auxiliar no diagnóstico [4].

No entanto, o processo de segmentação das artérias com base em imagens de ATC é extremamente complexa devido a diversos fatores. A anatomia das artérias coronárias, por exemplo, varia significativamente entre indivíduos. Outro fator importante é que, enquanto em algumas pessoas as artérias estão localizadas dentro do músculo cardíaco, em outras elas são envolvidas por uma camada de gordura. Além disso, as imagens de ATC frequentemente apresentam distorções e ruídos, o que pode comprometer a qualidade da análise durante o processo de segmentação. Pode-se destacar também que a estrutura tubular das artérias coronárias é complexa, com numerosas bifurcações e uma pequena porcentagem da área das mesmas é visível nos planos transversais [5]. Diante desses desafios, a segmentação precisa das artérias coronárias exige o desenvolvimento de algoritmos robustos e adaptáveis às diferentes variações anatômicas e à qualidade das imagens.

Neste contexto é importante destacar a iniciativa do projeto ImageCAS, que propõe um *benchmark* e disponibiliza um conjunto de dados de imagens de ATC, para a avaliar e servir de referência para o desenvolvimento de algoritmos de segmentação de artérias coronárias [5]. O projeto ImageCAS tem como objetivo promover a colaboração entre pesquisadores e o desenvolvimento de métodos de segmentação mais eficazes. O conjunto de dados disponibilizado pelo projeto é composto por imagens de ATC de 1000 pacientes, juntamente com um padrão de referência (*ground truth*) para avaliação dos algoritmos de segmentação. Os autores apresentam também uma proposta de divisão dos dados para treino e roteiros para testar os algoritmos disponibilizados, com diferentes conjuntos de parâmetros de entrada. Entretanto algumas questões importantes precisam ser avaliadas na utilização desses dados, como a resolução das imagens e a capacidade de generalização dos algoritmos para diferentes conjuntos de dados. O tipo de hardware a ser utilizado, tanto no treino quanto na inferência, também é um fator importante a ser considerado.

A disponibilização de *datasets* de imagens médicas tem impulsionado o desenvolvimento de algoritmos de segmentação. O projeto ImageCAS, por exemplo, disponibiliza um conjunto de imagens de ATC para a avaliação de algoritmos de segmentação de artérias coronárias [5]. Os autores fornecem também os código fonte dos algoritmos de segmentação utilizados no projeto, permitindo a reprodução dos resultados e a comparação com outros possíveis métodos, e destacam como suas principais contribuições terem coletado dados de 1000 pacientes para segmentação de artérias e terem disponibilizado este *dataset* de forma pública. O artigo também propõe um *benchmark* para segmentação composto por uma variedade de métodos existentes e um novo método de segmentação de referência. Os resultados da aplicação destes métodos no *dataset* proposto são apresentados e discutidos.

Diversos autores destacam a importância de se ter *datasets* públicos que sirvam de referência para pesquisas na área de segmentação de imagens médicas [6, 5]. Os autores argumentam que a disponibilização de *datasets* públicos é fundamental para a avaliação e comparação de algoritmos de segmentação, permitindo a reprodução dos resultados e a identificação de métodos mais eficazes. Além disso, a disponibilização de *datasets* públicos contribui para o avanço da pesquisa na área, uma vez que permite a colaboração entre pesquisadores e a comparação de diferentes abordagens.

Um dos métodos implementados, como parte do *benchmark* proposto, se baseia na abordagem de segmentação direta apresentada por [7]. No trabalho original os autores utilizam o que denominam de rede FCN (*Fully Convolutional Network*) tridimensional, que é adaptada para processamento de imagens de tomografias. Trata-se de uma das primeiras tentativa de usar aprendizado profundo 3D para segmentação de artérias coronárias.

A FCN é uma rede neural convolucional construída utilizando a arquitetura das redes U-net. A arquitetura U-net, proposta por [8], foi utilizada com sucesso em diversas tarefas de segmentação de imagens médicas [9]. A principal característica da arquitetura U-net é a presença de conexões residuais entre camadas, que permitem a passagem de informações de baixo nível para camadas mais profundas da rede. Isso é particularmente útil para a segmentação

de estruturas tubulares, como as artérias coronárias, pois possibilita a preservação de detalhes finos e a redução de falsos positivos.

Em [7] propõem também a incorporação de um mecanismo adicional, denominado de *Attention Gate* na estrutura de rede 3D FCN para melhorar a precisão. O *Attention Gate* foi introduzido com o objetivo de destacar os vasos em cada fatia ATC.

Os resultados apresentados por [5] para a segmentação direta utilizando a FCN 3D com *Attention Gate* corroboram o desempenho reportado por [7]. Deve-se levar em consideração que o treinamento foi feito com conjuntos diferente de dados. Na análise do método de segmentação direta, tanto [7] quanto [5] destacam ainda a possibilidade de se trabalhar sim e com a camada de *Attention Gate*, reduzindo as dimensões da imagem de entrada e modificando a quantidade de canais da rede convolucional, visando diminuir o tempo de processamento das imagens sem perda significativa de desempenho. A qualidade da segmentação é aferida utilizando o índice de *dice score*, métrica comumente utilizada para avaliar a sobreposição entre duas máscaras de segmentação. Entretanto os trabalhos não fazem uma descrição dos requisitos de hardware utilizados para treinamento e inferência dos modelos, assim como do tempo de execução e uso de memória. Estes podem ser fatores limitadores para a utilização dos métodos propostos em larga escala.

Neste estudo, utilizamos o conjunto de dados de imagens de ATC disponibilizados, para avaliar um dos métodos que faz parte de um *benchmark* de segmentação proposto por [5]. Avaliamos o desempenho desses métodos utilizando a métrica *dice score*, comparando os resultados com um padrão de referência disponibilizado junto com os dados. Experimentamos diferentes resoluções de imagem e propomos um método de ensemble para combinar os resultados dos diferentes algoritmos, visando melhorar a precisão da segmentação. Também fazemos uma análise do uso de recursos computacionais em termos de tempo de execução e uso de memória.

O restante do artigo é organizado da seguinte forma. A Seção 2 fornece uma visão geral dos trabalhos relacionados. Na Seção 2, são apresentados detalhes do conjunto de dados proposto e uma análise do algoritmo de segmentação utilizado incluindo a proposta de ensemble feita com base em modelos treinados com diferentes conjuntos de dados. Os resultados experimentais são apresentados e discutidos na Seção 4, e a Seção 5 apresenta as conclusões do artigo.

2 Materiais e Métodos

O conjunto de dados e os algoritmos do *benchmark* utilizados neste estudo está disponível na plataforma kaggle¹ na forma de um arquivo de 89GB. O banco de imagens está composto de ATC capturadas por um escâner de fonte dupla Siemens de 128 cortes de 1000 pacientes. As imagens têm tamanhos de $512 \times 512 \times (206 \text{ a } 275)$ voxels, com uma resolução de $0,29 - 0,43 \text{ mm}^2$ e espaçamento de $0,25 - 0,45 \text{ mm}$.

Na amostra se tem um total de 414 mulheres e 586 homens, com idades médias de 59,98 e 57,68, respectivamente. As artérias coronárias esquerda e direita em cada imagem foram rotuladas independentemente por dois radiologistas, e seus resultados foram validados de forma cruzada. Em caso de discrepância, um terceiro radiologista fez a anotação e o resultado final foi determinado por consenso.

Analisando os rótulos disponibilizados e comparando o volume de artérias com o volume total da imagem, observamos que a porcentagem de área das artérias coronárias é pequena, variando de 0,1% a 0,5%. Isso pode ser um fator limitante para a segmentação, uma vez que a estrutura tubular das artérias coronárias é complexa, com numerosas bifurcações e uma pequena porcentagem da área das mesmas é visível nos planos transversais. Métricas como a acurácia e a sensibilidade podem ser afetadas por essa característica. Por este motivo, o uso de métricas como o *dice score* é mais adequada para avaliar a qualidade da segmentação.

O método de segmentação direta, analisado neste trabalho, utiliza um rede FCN-AG baseada na arquitetura U-net 3D como o representada na Fig. 1. A implementação proposta por [5] é feita em Pytorch e está disponível no repositório do projeto ImageCAS. A rede permite analisar as imagens na sua resolução original. Entretanto a demanda de memória para processamento pode ser alto, sobre tudo em função do número de canais utilizados na rede. Os autores propõem uma configuração padrão de 4 canais para a rede, mas a quantidade de canais pode ser ajustada levando em consideração que a diminuição do número de canais pode afetar a qualidade da segmentação.

Uma alternativa para para reduzir o consumo de memória e o tempo de processamento é a redução das dimensões da imagem de entrada. A implementação proposta em [5] permite que as imagens de entrada sejam utilizadas para treinamento em três versões diferente: Alta resolução ($512 \times 512 \times Z$), resolução média ($256 \times 256 \times Z/2$) e baixa resolução ($128 \times 128 \times Z/4$). Entretanto, a redução da resolução pode afetar a qualidade da segmentação, uma vez que a estrutura tubular das artérias coronárias é complexa, com numerosas bifurcações e uma pequena porcentagem da área das mesmas é visível nos planos transversais.

Uma combinação de redução de dimensão com aumento do número de canais pode ser uma alternativa para melhorar a qualidade da segmentação sem aumentar significativamente o consumo de memória. Com esta finalidade

¹<https://www.kaggle.com/datasets/xiaoweixumedicalai/imagecas>

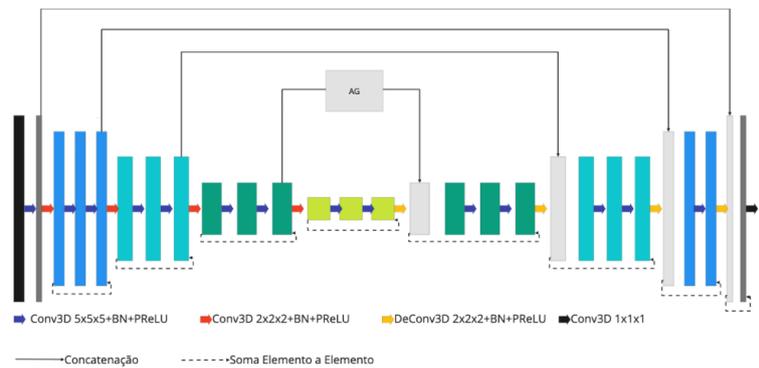


Figura 1: Representação da rede FCN-AG proposta por [7].

a quantidade de canais e a resolução da imagem de entrada devem ser ajustadas de forma a manter um equilíbrio entre a qualidade da segmentação e o consumo de recursos computacionais. [5] fazem uma análise detalhada do impacto da resolução da imagem e do número de canais na qualidade da segmentação. Entretanto, não foi incluída na análise detalhes relacionados a consumo de recursos computacionais.

Para o treinamento do modelos [5] propõe utilizar um subconjunto de 200 imagens divididas em quatro grupos, utilizando a técnica de K-Fold. Com esta finalidade os autores dividem o *dataset* de 1000 em 5 grupos de 200 imagens cada. Um arquivo com a proposta de como dividir o primeiro desses conjuntos, visando a implementação do K-Fold, também é disponibilizada. A divisão dos dados em grupos menores permite a avaliação do desempenho dos modelos com diferentes conjuntos de dados, com o objetivo de identificar a capacidade de generalização dos algoritmos para diferentes variações anatômicas e de qualidade das imagens.

Cada treino do K-Fold foi realizado por 30 épocas, e ao final de cada uma se armazena o valor médio da função de perda tanto para o conjunto de treino quanto para o conjunto de validação. Para realizar a análise dos resultados obtidos com os diferentes conjuntos de dados, [5] propõem a utilização da métrica *dice score*. O *dice score* é uma métrica comumente utilizada para avaliar a sobreposição entre duas máscaras de segmentação. Esta métrica varia de 0 a 1, sendo 0 indicativo de nenhuma sobreposição e 1 indicativo de sobreposição perfeita.

Uma vez realizado o treinamento com cada uma das etapas do K-Fold a inferência do grupo de teste, composta pelas 800 imagens que ficaram de fora do treino, permite avaliar a qualidade da segmentação. Procurando melhorar o desempenho e aproveitar os modelos já treinados, propomos a construção de um ensemble com os modelos treinados no K-Fold. O ensemble é feito a partir da combinação dos resultados de diferentes modelos, visando melhorar a precisão da segmentação.

Para realizar o treinamento e as inferências foi utilizada uma GPU NVIDIA RTX A5000, com 24GB de memória, dois processadores Intel(R) Xeon(R) Gold 5318Y de 2,10GHz, com 24 núcleos e 48 threads cada e 512GB de memória RAM. O tempo de treinamento e inferência foi monitorado para avaliar o impacto da resolução da imagem e do número de canais na qualidade da segmentação.

3 Resultados e Discussão

Para avaliar o desempenho dos modelos foram utilizadas as configurações apresentadas na Tabela 1. Em todos os casos foi realizado o treinamento com o mesmo conjunto de 200 imagens utilizando um K-Fold de 4 grupos. A inferência foi realizada com o grupo de teste, composto pelas 800 imagens restantes.

A Fig. 2 mostra a evolução da função de perda para cada um dos grupos de treino do K-Fold no modelo FCN no experimento 1. A função de perda é calculada a partir da diferença entre a máscara de segmentação obtida e a máscara de referência. Pode-se observar que os grupo de treino parece continuar "aprendendo" mesmo após 30 épocas, sugerindo que o treinamento poderia ser estendido para mais épocas. Entretanto o resultado com o grupo de teste parece indicar que o modelo já atingiu o ponto de convergência.

A Tabela 2 apresenta os resultados obtidos para os diferentes experimentos. O *dice score* foi determinado para cada um dos grupos de teste do K-Fold e o valor médio e o desvio padrão entre os grupos foi calculado. Pode-se observar que o modelo FCN-AG, experimento 2, obteve um desempenho ligeiramente superior em comparação com o modelo FCN, experimento 1. Entretanto os dois modelos apresentam um alto consumo de memória e de tempo de execução. A redução da resolução da imagem de entrada, experimentos 3 e 5, resultou em uma diminuição do *dice score*. Entretanto, o aumento do número de canais, experimentos 4 e 6, resultou em um aumento do *dice score*. A combinação de redução de resolução e aumento do número de canais, experimentos 4 e 6, resultou em

Tabela 1: Parâmetros de entrada dos treinamentos.

Experimento	Dimensões	Método	Canais
1	512x512xZ	FCN	4
2	512x512xZ	FCN-AG	4
3	256x256xZ/2	FCN	4
4	256x256xZ/2	FCN	12
5	128x128xZ/4	FCN	4
6	128x128xZ/4	FCN	12

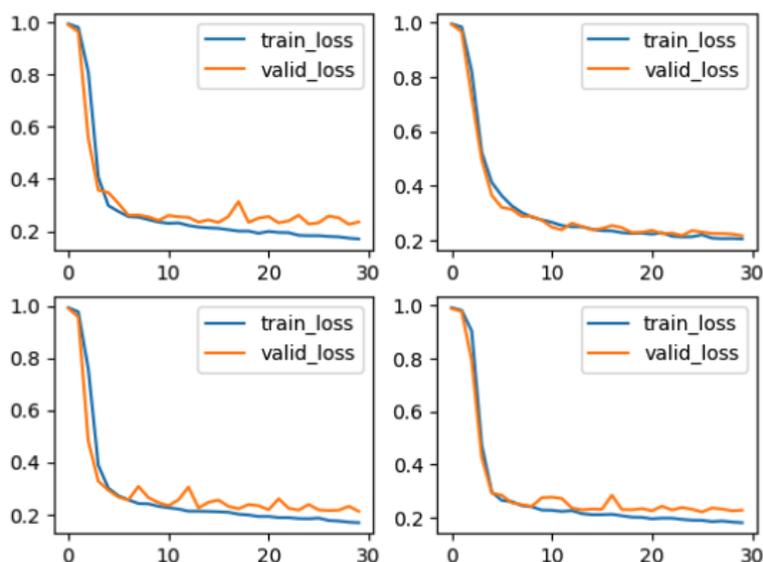


Figura 2: Evolução da função de perda, do grupo de treino e de validação, para cada um dos grupos de treino do K-Fold de experimento 1.

um desempenho superior na segmentação, em relação a apenas redução do tamanho das imagens. Estes resultados confirmam os relatados por [5] e destacam a importância de se ajustar a resolução da imagem e o número de canais para obter um desempenho superior na segmentação.

Tabela 2: Resultados experimentais.

Experimento	Dice Score	Desvio Padrão	Tempo de Treino	Uso de Memória
1	0.78	0.003	3:16	23942
2	0.79	0.006	3:15	23942
3	0.72	0.009	00:52	6538
4	0,73	0.007	01:22	16658
5	0,51	0.062	00:47	4516
6	0,57	0.013	00:48	9806

Finalmente, com base nos modelos treinados no K-Fold do experimento 2, foi montado um ensemble de modelos para avaliar o impacto na qualidade da segmentação. O ensemble foi feito a partir da combinação dos resultados dos modelos treinados, visando melhorar a precisão da segmentação. O *dice score* médio obtido com o ensemble foi de

0.80, um desempenho superior em comparação com os modelos individuais. O histograma apresentado na Fig. 3 mostra a distribuição do *dice score* obtido com o ensemble. Pode-se observar que tem menos de 10 imagens com *dice score* abaixo de 0,65. Ainda que a média esteja em 0,80, se observa uma grande quantidade de imagens com *dice score* entre 0,80 e 0,85.

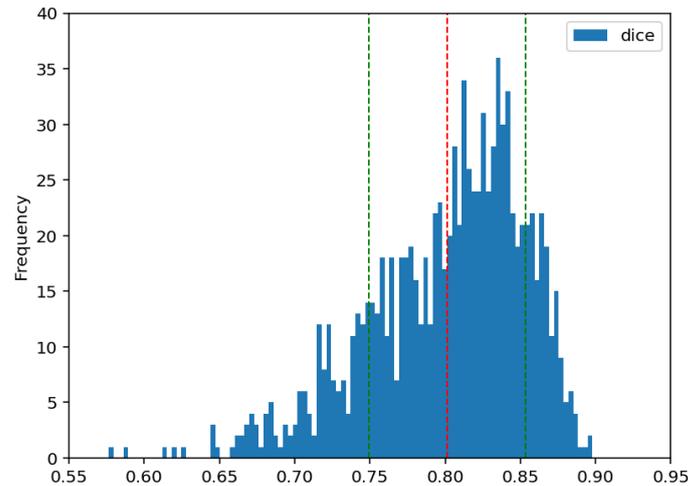


Figura 3: Histograma de distribuição de *dice score* entre as 1000 imagens do conjunto utilizando a inferência feita com o ensemble de modelos.

4 Conclusões

Neste estudo, avaliamos um conjunto de imagens de ATC disponibilizado pelo projeto ImageCAS e comparamos diferentes algoritmos de segmentação, incluindo um método de segmentação direta proposto. Avaliamos o desempenho dos algoritmos utilizando o índice de *dice score*, comparando os resultados com um padrão de referência (*ground truth*). Experimentamos diferentes resoluções de imagem para analisar o impacto no desempenho e no consumo de recursos computacionais. Além disso, propomos um método de ensemble para combinar os resultados de diferentes algoritmos, visando melhorar a precisão da segmentação. Os resultados obtidos demonstram que o método de ensemble proposto alcança um desempenho superior em comparação com os algoritmos individuais.

Os resultados obtidos confirmam a importância de se ajustar a resolução da imagem e o número de canais para obter um desempenho superior na segmentação. A redução da resolução da imagem de entrada resultou em uma diminuição do *dice score*, enquanto o aumento do número de canais resultou em um aumento do *dice score*. Estudos mais aprofundados devem ser realizados para avaliar o impacto da resolução da imagem e do número de canais na qualidade da segmentação. Um ponto importante a ser considerado é o consumo de recursos computacionais, uma vez que o treinamento e a inferência dos modelos podem exigir uma quantidade significativa de memória e tempo de processamento. A utilização de hardware de alto desempenho, como GPUs, pode ser necessária para treinar e inferir os modelos em um tempo razoável.

Agradecimentos

Os autores agradecem ao Ministério de Ciência Tecnologia e Inovação (MCTI) e a Associação para Promoção da Excelência do Software Brasileiro (Softex) pelo apoio financeiro à execução desta pesquisa mediante o programa Prioritário PNM Design (01245.019446/2022-11).

Referências

- [1] World Heart Federation, “World heart report 2023: Confronting the world’s number one killer,” World Heart Federation, Geneva, Switzerland, Relatório técnico, 2023. Disponível em: <https://www.world-heart-federation.org/world-heart-report/>
- [2] W. Huang, L. Huang, Z. Lin, S. Huang, Y. Chi, J. Zhou, J.-M. Zhang, ru san tan, e L. Zhong, “Coronary artery segmentation by deep learning neural networks on computed tomographic coronary angiographic images,” em *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2018, pp. 608–611. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8512328>
- [3] A. Colombo e F. Giannini, “Is it time to replace conventional angiography with coronary computed tomography?” *European Heart Journal*, vol. 39, no. 41, pp. 3699–3700, 2018. Disponível em: <https://doi.org/10.1093/eurheartj/ehy578>
- [4] Q. Xie, L. Zhou, Y. Li, R. Zhang, H. Wei, G. Ma, Y. Tang, e P. Xiao, “Comparison of prognosis between coronary computed tomography angiography versus invasive coronary angiography for stable coronary artery disease: a systematic review and meta-analysis,” *Frontiers in Cardiovascular Medicine*, vol. 10, p. 1010536, 2023. Disponível em: <https://doi.org/10.3389/fcvm.2023.1010536>
- [5] A. Zeng, C. Wu, G. Lin, W. Xie, J. Hong, M. Huang, J. Zhuang, S. Bi, D. Pan, N. Ullah, K. N. Khan, T. Wang, Y. Shi, X. Li, e X. Xu, “ImageCAS: A large-scale dataset and benchmark for coronary artery segmentation based on computed tomography angiography images,” *Computerized Medical Imaging and Graphics*, vol. 109, p. 102287, 2023. Disponível em: <https://doi.org/10.1016/j.compmedimag.2023.102287>
- [6] A. Rouhollahi, J. N. Willi, S. Haltmeier, A. Mehrtash, R. Straughan, H. Javadikasgari, J. Brown, A. Itoh, K. I. de la Cruz, E. Aikawa, E. R. Edelman, e F. R. Nezami, “CardioVision: A fully automated deep learning package for medical image segmentation and reconstruction generating digital twins for patients with aortic stenosis,” *Computerized Medical Imaging and Graphics*, vol. 109, p. 102289, 2023. Disponível em: <https://doi.org/10.1016/j.compmedimag.2023.102289>
- [7] Y. Shen, Z. Fang, Y. Gao, N. Xiong, C. Zhong, e X. Tang, “Coronary Arteries Segmentation Based on 3D FCN with Attention Gate and Level Set Function,” *IEEE Access*, vol. 7, pp. 42 826–42 835, 2019. Disponível em: <https://doi.org/10.1109/ACCESS.2019.2908039>
- [8] O. Ronneberger, P. Fischer, e T. Brox, “U-Net: Convolutional Networks for Biomedical Image Segmentation,” em *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, 2015, pp. 234–241, arXiv: 1505.04597. Disponível em: <http://arxiv.org/abs/1505.04597>
- [9] C. Huang, H. Han, Q. Yao, S. Zhu, e S. K. Zhou, “3D U-Net: A 3D Universal U-Net for Multi-Domain Medical Image Segmentation,” em *Medical Image Computing and Computer Assisted Intervention – MICCAI 2019*, 2019, pp. 291–299, arXiv: 1909.06012. Disponível em: <http://arxiv.org/abs/1909.06012>