

Segmentação Automática de Calcificação da Artéria Coronária em Imagem de Tomografia Computadorizada Utilizando Aprendizado Profundo

Alan C. Araújo* Aristóфанes C. Silva* João M. Pedrosa**
Anselmo C. Paiva* Italo F. S. Silva* João O. B. Diniz***

* Faculdade de Engenharia Elétrica, Universidade Federal do Maranhão, MA, (e-mail: alan.araujo@nca.ufma.br, ac.silva@ufma.br, paiva@deinf.ufma.br, italo.francyles@ufma.br).

** Instituto de Engenharia de Sistemas e Computadores, Tecnologia e Ciência, Porto, Portugal, (e-mail: joao.m.pedrosa@inesctec.pt)

*** Insituto Federal de Educação, Ciência e Tecnologia, MA, (e-mail: joao.bandeira@ifma.edu.br)

Abstract: One of the indicators of possible occurrences of cardiovascular diseases is the amount of coronary artery calcium. Recently, approaches using new technologies such as deep learning have been used to help identify these indicators. This work proposes a segmentation method for calcification of the coronary arteries that has 3 steps: extraction of the ROI using U-Net with batch normalization after convolution layers, segmentation of the calcifications and removal of false positives using U-Net with EfficientNetB0. The method uses histogram matching as preprocessing in order to increase the contrast between tissue and calcification and normalize the different types of exams. Tests were performed between different architectures where the best approach achieved 96.8% F1-Score, 98.3% precision and 97,0% recall in the OrcaScore Dataset.

Resumo: Um dos indicadores de possíveis ocorrências de doenças cardiovasculares é a quantidade de cálcio nas artérias coronárias. Recentemente, abordagens utilizando novas tecnologias, como o aprendizado profundo, auxiliaram na identificação desses indicadores. Este trabalho propõe um método de segmentação para calcificação das artérias coronárias que possui 3 etapas: extração da região de interesse (ROI) utilizando U-Net com *batch normalization* após camadas de convolução, segmentação das calcificações e remoção de falsos positivos utilizando U-Net com EfficientNetB0. O método utiliza a técnica de histogram matching como pré-processamento, a fim de aumentar o contraste entre tecido e calcificação e normalizar os diferentes tipos de exames. Foram realizados testes entre diversas arquiteturas onde a melhor abordagem alcançou uma pontuação F1 de 96,8%, precisão de 98,3% e sensibilidade de 97,0% no conjunto de dados OrcaScore.

Keywords: Coronary artery calcium; Segmentation; U-Net; EfficientNetB0.

Palavras-chaves: Calcificação da artéria coronária; Segmentação; U-Net; EfficientNetB0.

1. INTRODUÇÃO

As doenças cardiovasculares são as principais causas de mortalidade global (Wang et al., 2016). Um indicador da ocorrência potencial de doença cardiovascular é a quantidade de calcificação nas artérias coronárias (CAC) (Föllmer et al., 2022). A CAC é comumente calculada por meio de exames de tomografia computadorizada, que podem ser realizados com ou sem contraste. O exame com contraste, conhecido como angiografia coronária por tomografia computadorizada (CCTA), envolve a injeção de uma substância radioativa que destaca os tecidos moles, auxiliando na visualização tanto dos tecidos moles (coração, artérias e veias) quanto dos tecidos duros (estruturas ósseas). No entanto, devido ao uso de uma substância radioativa, esse exame é contraindicado para certos pacientes. Em tais casos, é realizado um exame de tomografia computadorizada

sem contraste (CSCT), que, por sua vez, apresenta um contraste menor entre tecidos moles e duros, tornando sua visualização mais desafiadora (Gogin et al., 2021).

No passado, era necessária a interação humana para diferenciar o cálcio nas artérias de outras calcificações, como aorta e ossos (Wang et al., 2020). Devido aos avanços tecnológicos, surgiram novos métodos de trabalhar com imagens e grandes quantidades de dados, e a inteligência artificial trouxe novas abordagens para problemas envolvendo imagens. Consequentemente, métodos foram desenvolvidos para identificar automaticamente a CAC, incluindo abordagens baseadas em aprendizado profundo (Zhang et al., 2019). Essas abordagens têm sido aplicadas com sucesso em imagens médicas, auxiliando no monitoramento, especialmente na detecção de achados sutis que um médico poderia deixar passar despercebido e pequenos detalhes invisíveis a olho nu (de Vos et al., 2019).

Apesar dos esforços significativos para apoiar o desenvolvimento de métodos automáticos de identificação de CAC baseados principalmente em aprendizado profundo, ainda há espaço para novos experimentos e melhorias. Portanto, o principal objetivo deste artigo é propor um método em cascata para segmentação de calcificações nas artérias coronárias. O método proposto utiliza *histogram matching* para aumentar o contraste entre a calcificação e o tecido, simulando o exame com contraste, eliminando assim a necessidade do paciente realizá-lo. O método envolve o uso de uma U-Net com *batch normalization* após as camadas convolucionais para extrair a região de interesse (ROI) e uma U-Net com o *encoder* substituído pela EfficientNetB0 para segmentação da calcificação. Além disso, é incluída uma etapa específica para remover falsos positivos, que são prevalentes nesse problema de segmentação.

Este artigo está organizado da seguinte forma: Na Seção 2, discutimos trabalhos relacionados sobre segmentação de calcificações nas artérias coronárias, explorando avanços em métodos previamente publicados. A Seção 3 fornece informações detalhadas sobre o método proposto para segmentação de calcificações. Os resultados são apresentados na Seção 4 e, finalmente, a Seção 5 conclui o artigo resumindo as descobertas e discutindo trabalhos futuros.

2. TRABALHOS RELACIONADOS

Nesta seção, apresentamos trabalhos da literatura que estão relacionados ao problema proposto. Os critérios para seleção dos trabalhos relacionados foram estudos que utilizaram redes totalmente convolucionais (FCNs) para segmentação de calcificações cardíacas e não utilizaram exames com contraste.

Em Zhang et al. (2019), é utilizada uma rede DenseRAU-net, que combina Dense U-Net, ResNet e convolução dilatada. As imagens são pré-processadas redimensionando-as para 512×512 pixels. A função de perda é uma combinação de Bootstrap e IoU para equilibrar efetivamente a classe de fundo e a classe de calcificação. O modelo é treinado em tomografias computadorizadas torácicas sem contraste, utilizando uma abordagem 2.5D, e avaliado em tomografias cardíacas. Os resultados mostram um F1-Score notável de 95,4% e uma precisão de 99,1%. No entanto, não é realizado um pré-processamento para minimizar os problemas causados pelo baixo contraste entre tecidos e calcificações em tomografias computadorizadas sem contraste.

Em contraste, Föllmer et al. (2022) introduz um modelo de várias tarefas para a segmentação simultânea da região da artéria coronária e das calcificações. O modelo foi treinado e avaliado em três conjuntos de dados, nomeadamente DISCHARGE, OrcaScore e CADMAN. Durante o treinamento, os autores utilizaram a função de perda ponderada por incerteza Kendall et al. (2018). O método proposto alcançou um F1-Score de 92,8% para a tarefa de segmentação de calcificações. No entanto, esse método não possui um mecanismo para mitigar as diferenças nos exames realizados em diferentes tomógrafos computadorizados, o que dificulta o processo de aprendizado da rede.

Enquanto em Gogin et al. (2021), os autores utilizam cinco modelos 3D U-Net treinados do zero utilizando o otimizador ADAM e o coeficiente de Dice como função

de perda. O resultado final é obtido por meio de votação majoritária entre os cinco modelos. Como etapa de pré-processamento, a resolução das imagens é reduzida para 2,5 ou 3 mm. Para recuperar informações perdidas, todos os voxels acima de 130 UH na imagem original são intensificados na imagem de resolução reduzida. Um total de 783 pacientes é utilizado para treinar os cinco modelos 3D U-Net. O método alcança um F1-Score de 97,4% no conjunto de dados OrcaScore. No entanto, esse modelo não possui um mecanismo para evitar ou remover falsos positivos, que são comuns nesse problema devido as calcificações presentes em regiões como a aorta e a válvula mitral.

Apesar dos inúmeros métodos propostos, obter uma segmentação precisa das calcificações continua sendo um desafio devido ao baixo contraste entre tecidos e calcificações em exames sem contraste, assim como às variações entre os exames adquiridos por diferentes tomógrafos. Conseqüentemente, o desenvolvimento de um método de segmentação que utilize pré-processamento para aumentar o contraste entre tecido e calcificação em exames de CT sem contraste, bem como normalizar os diversos exames realizados em diferentes tomógrafos, pode facilitar sua identificação. Além disso, incorporar uma etapa específica para remoção de falsos positivos, que é comum nesse problema de segmentação de calcificações nas artérias coronárias, seria benéfico.

3. MATERIAIS E MÉTODOS

Esta seção apresenta informações sobre o conjunto de dados utilizado, o método proposto e as técnicas aplicadas.

3.1 Base de imagens

Para a etapa de extração da ROI, foi utilizada uma base de dados pública chamada CT Heart, composta por 25 exames de tomografia computadorizada com anotações do coração. Essa base de dados contém um total de 2532 fatias de imagem. Durante o treinamento, foram aplicadas três técnicas de aumento de dados, incluindo espelhamento horizontal, espelhamento vertical e rotação de 45° . No final, a base consistiu em 8610 imagens.

Para a etapa de segmentação de calcificações, foi utilizada a base de dados pública OrcaScore, que consiste em exames de tomografia computadorizada de 32 pacientes, totalizando 1540 fatias de imagem. Essa base de dados inclui exames adquiridos em quatro máquinas de tomografia diferentes, em quatro hospitais distintos, proporcionando uma maior diversidade de exames. Técnicas de aumento de dados foram aplicadas ao conjunto de treinamento, incluindo espelhamento horizontal, espelhamento vertical e rotação de 45° . No final, a distribuição dos dados consistiu em 4700 imagens.

O banco de dados de imagens para a etapa de remoção de falsos positivos foi formado por meio de pré-processamento, que envolveu a extração de uma região de interesse (ROI) de 96×96 pixels a partir das predições feitas na etapa de segmentação de calcificações, bem como ROIs das máscaras na base de dados OrcaScore. Assim, o banco de dados consiste em 198 imagens verdadeiramente positivas e 32 imagens falsamente positivas. Devido à quantidade limitada de dados, técnicas de aumento de dados são aplicadas para gerar novas imagens. Para o

conjunto de treinamento verdadeiramente positivo, são realizadas técnicas de espelhamento horizontal, espelhamento vertical e rotação de 45° , resultando em um total de 1036 imagens verdadeiramente positivas. Para o conjunto de falsos positivos, um maior número de imagens é gerado para equilibrar o banco de dados. As técnicas de aumento aplicadas incluem espelhamento horizontal, espelhamento vertical e rotação de 10 a 70° em incrementos de 5° , resultando em um total de 240 imagens falsamente positivas.

3.2 Método proposto

O método proposto segue uma abordagem em cascata, em que a saída de cada etapa serve como entrada para a etapa subsequente. Ele é dividido em três etapas, sendo elas: extração da ROI, segmentação de calcificações e remoção de falsos positivos. Cada etapa é projetada para abordar um aspecto específico da tarefa, conforme ilustrado na Figura 1.

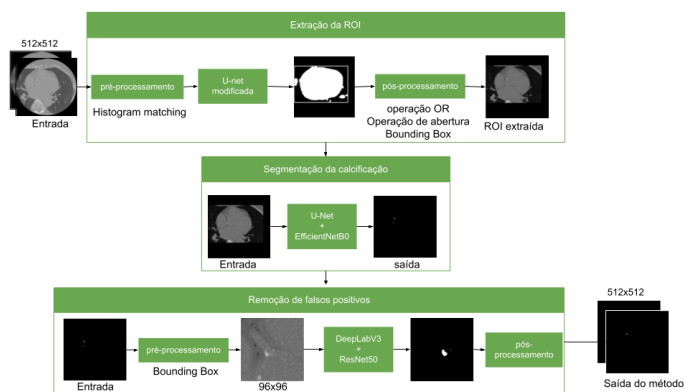


Figura 1. Fluxograma do método proposto.

As variações nos exames de tomografia computadorizada podem ser significativas dependendo da máquina de tomografia, fabricante, hospital e outros fatores. Portanto, foi aplicada a técnica de *histogram matching* (Gonzalez, 2009), onde realiza-se a modificação do histograma de uma imagem baseada em um histograma de referência, para tornar os exames mais semelhantes entre si e realçar o contraste entre a ROI e outras regiões. Além disso, essa etapa de pré-processamento também aumenta o contraste entre as calcificações e os tecidos circundantes, o que auxilia nas etapas subsequentes. Para determinar a imagem de referência, realizamos uma segmentação inicial da ROI. A fatia do paciente com o maior valor de F1-Score nessa segmentação inicial foi selecionada como a imagem de referência. Um exemplo da aplicação da correspondência de histograma pode ser visto na Figura 2.




Figura 2. Aplicação de *histogram matching*: (a) imagem original (b) imagem de referência e (c) imagem com histograma modificado.

A arquitetura da rede utilizada na primeira etapa foi a U-Net modificada proposta por Yoshida et al. (2021). A estrutura consiste em camadas de *down-sampling* e *up-sampling*, conferindo-lhe um formato em forma de U. Os blocos de *down-sampling* consistem em camadas sucessivas de convolução 3×3 e camadas de normalização em lote, seguidas de funções de ativação ReLU e operações de max-pooling 2×2 . O número de filtros é duplicado em cada bloco, começando com 64 filtros e alcançando um total de 1024. Por outro lado, os blocos de *up-sampling* consistem em camadas de convolução 2×2 , sendo que cada bloco respectivo da seção de *down-sampling* possui uma camada de convolução 3×3 correspondente. A última camada inclui uma convolução transposta que gera uma imagem com as mesmas dimensões da imagem de entrada.

Após a segmentação inicial da ROI, uma máscara final é formada realizando uma operação morfológica OR (Gonzalez, 2009) em todas as segmentações das fatias do paciente. Isso significa que, para cada pixel na máscara final, se pelo menos uma segmentação o considerar parte da ROI, ele será marcado como pertencente à ROI. Um exemplo da operação OR aplicada ao problema pode ser visto na Figura 3.




Figura 3. Exemplo da operação morfológica OR: (a) fatia 1, (b) fatia N e (c) máscara final.

Além disso, é aplicada uma operação de abertura (Gonzalez, 2009) para eliminar possíveis artefatos presentes na máscara final. Nessa etapa, é utilizado um elemento estruturante retangular de tamanho fixo de 7×7 . Um exemplo da operação de abertura pode ser visto na Figura 4.




Figura 4. Exemplo de operação de abertura: (a) imagem original e (b) imagem resultante.

Pode-se observar que a operação remove objetos pequenos e linhas finas da imagem, preservando a forma e o tamanho dos objetos maiores. Por fim, é criada uma *bounding box* ao redor da máscara final para garantir que a ROI tenha sido extraída, como mostrado na Figura 5.

Na etapa de segmentação de calcificações, é realizada a segmentação inicial das calcificações nas artérias coronárias utilizando a arquitetura escolhida. Devido ao fato da imagem de entrada nessa etapa ser apenas a ROI extraída na etapa anterior, evita-se alguns falsos positivos em regiões como esterno e coluna. Contudo, ainda existem




Figura 5. Exemplo de : (a) bounding box depois do pós-processamento e (b) ROI extraída da primeira etapa

falsos positivos dentro da ROI, sendo esses falsos positivos principalmente calcificações na aorta.

A arquitetura de rede neural utilizada nas etapas dois e três foi a U-Net modificada com o *encoder path* baseado no EfficientNetB0. A estrutura padrão da U-Net está presente nas camadas de *up-sampling*, enquanto a parte de *down-sampling* apresenta o modelo EfficientNetB0, que inclui uma camada convolucional 3×3 com 64 filtros. Em seguida, são adicionados 5 blocos de convolução profunda, cada um consistindo de uma camada convolucional 3×3 e uma camada convolucional 1×1 . Cada bloco de decodificação contém uma camada convolucional transposta de tamanho 2×2 obtida a partir da camada anterior com um *stride* de 2, concatenada com uma convolução 1×1 para cada bloco correspondente na seção de *down-sampling*. Na última camada, ocorre uma convolução transposta, retornando uma imagem de saída com as mesmas dimensões da imagem de entrada.

Na etapa de remoção de falsos positivos, técnicas de pré-processamento e pós-processamento são aplicadas para remover os falsos positivos causados principalmente por calcificações em outras regiões da ROI que não fazem parte das artérias coronárias, como a aorta.

Durante a subetapa de pré-processamento, é criada uma *bounding box* em torno das predições feitas na etapa de segmentação de calcificações. Essas *bounding box* são expandidas para o tamanho de 96×96 pixels e, em seguida, uma ROI é formada a partir da imagem de 512×512 pixels, conforme mostrado na Figura 6. Dessa forma, a ROI fornece informações contextuais sobre a localização da segmentação de calcificações, auxiliando nas suas identificações.




Figura 6. Exemplo de: (a) imagem 512×512 com *bounding box* representado pelo quadrado vermelho (b) *bounding box* 96×96 e (c) ROI 96×96 extraída da imagem original

Durante a subetapa de pós-processamento, as imagens de saída dessa etapa têm tamanho de 96×96 pixels. Em seguida, essas imagens são colocadas na mesma posição da imagem original da qual foram extraídas (imagem de 512×512 pixels), resultando em uma imagem de saída

do método com tamanho de 512×512 pixels, o mesmo tamanho da imagem de entrada.




Figura 7. Exemplo de: (a) imagem de saída 96×96 e (b) imagem de saída do método 512×512

3.3 Configuração dos experimentos

Para o treinamento da etapa de extração da ROI, a Dice loss (Sudre et al., 2017) foi escolhida como função de perda devido ao seu melhor desempenho em comparação com a Focal loss e a entropia cruzada. Foi utilizado a base CT Heart, que consistiu em 6076 imagens para treinamento, 506 imagens para validação e 506 imagens para teste. O treinamento foi realizado por 40 épocas, com um *batch size* de 2 e uma taxa de aprendizado de $1e-4$. Além disso, a técnica de *Early Stopping* foi utilizada com uma paciência de 7 épocas. Esses experimentos, juntamente com todos os outros, foram conduzidos em um hardware com a seguinte configuração: uma placa de vídeo NVIDIA GTX 1660 Super com 6 GB de VRAM.

Para o treinamento da segunda etapa, a Focal loss (Lin et al., 2017) foi utilizada como função de perda, pois proporciona melhores resultados quando há desequilíbrio de classes. A base de dados utilizada foi a OrcaScore, onde a distribuição dos dados consistiu em 4248 imagens para treinamento, 150 imagens para validação e 301 imagens para teste. O treinamento foi realizado por 50 épocas, com um *batch size* de 4 e uma taxa de aprendizado de $1e-4$. A técnica de *Early Stopping* também foi empregada com uma paciência de 5 épocas.

Para o treinamento da terceira etapa, foi utilizada a Focal Loss. A base foi dividida em 1266 imagens para treino, 36 imagens para validação e 36 imagens para teste. O treinamento foi realizado por 50 épocas, com um *batch size* de 24 e uma taxa de aprendizado de $1e-4$. Além disso, a técnica de *Early Stopping* foi empregada com uma tolerância de 7 épocas.

3.4 Avaliação dos resultados

Para avaliação dos resultados foram utilizadas as métricas de F1-Score, precisão e sensibilidade (Chinchor and Sundheim, 1993). A precisão (P) mede a proporção de previsões de classe positivas corretas em relação ao número total de amostras classificadas como positivas (Equação 1). Sensibilidade (S) mede a proporção de amostras verdadeiras positivas que foram classificadas corretamente pelo modelo em relação ao número total de amostras positivas (Equação 2). F1-Score é a média harmônica entre precisão e sensibilidade (Equação 3).

$$P = \frac{VP}{VP + FP} \quad (1)$$

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

$$F1 - Score = 2 \times \frac{P \times S}{P + S} \quad (3)$$

Onde VP significa verdadeiros positivos, FP por sua vez significa falsos positivos e FN representa os falsos negativos.

4. RESULTADOS E DISCUSSÃO

Esta seção descreve os resultados do treinamento das arquiteturas e das etapas do método proposto para segmentação de calcificações nas artérias coronárias.

Na Tabela 1, pode-se observar uma melhoria na U-Net modificada em comparação com a U-Net original para a tarefa de extração da ROI. É importante observar que essas métricas foram obtidas testando apenas no conjunto de dados CT Heart, pois ele contém anotações do coração. A extração da ROI foi realizada no conjunto de dados OrcaScore e pode ser visualizada na Figura 8.

Tabela 1. Comparação de arquiteturas para extração da ROI

Arquitetura	F1-Score	Precisão	Sensibilidade
U-Net	63,0	93,3	63,2
U-Net modificada	85,0	96,8	85,4




Figura 8. Exemplo de extração da ROI na base OrcaScore: (a) paciente 1 (b) paciente 2 e (c) paciente 3

Foram realizados testes em imagens com e sem *histogram matching* para validar a melhoria das métricas quando diferentes tipos de imagens são mais semelhantes entre si, além de realçar o contraste entre calcificações e tecidos. A comparação entre esses testes pode ser visualizada na Tabela 2.

Tabela 2. Comparação entre imagens com e sem *histogram matching*

Imagem	F1-Score	Precisão	Sensibilidade
sem <i>histogram matching</i>	12,3	11,3	13,7
com <i>histogram matching</i>	81,7	95,0	84,2

Após comparar os pré-processamentos, foram realizados experimentos utilizando outras arquiteturas, especificamente a U-Net com outras modificações no *encoder path*, como ResNet-50 e EfficientNetB0. Isso permitiu avaliar arquiteturas com mais parâmetros e estruturas mais profundas. A Tabela 3 mostra as métricas obtidas por cada rede na tarefa de segmentação de calcificações nas artérias coronárias.

A U-Net modificada com EfficientNetB0 foi escolhida porque apresentou um maior F1-Score, alcançando assim uma

Tabela 3. Comparação entre arquiteturas na segmentação de calcificação

Arquitetura	F1-Score	Precisão	Sensibilidade
U-Net + Resnet-34	95,8	97,9	96,6
U-Net + Resnet-50	95,6	98,2	95,4
U-Net + Resnet-101	94,6	97,5	96,1
U-Net + EfficientNetB0	96,6	98,0	97,2
U-Net + EfficientNetB3	96,0	97,5	97,5
U-Net + EfficientNetB5	90,7	93,4	90,5

média harmônica maior entre Precisão e Especificidade. Após confirmar a eficácia da arquitetura para segmentar calcificações nas artérias coronárias, o método foi validado usando *cross validation*. A Tabela 4 exibe os valores das métricas, média e desvio padrão para cada *fold* de validação. Como a divisão entre treinamento e teste foi de 75%/25%, a validação cruzada foi realizada com 4 *folds*.

Tabela 4. Resultados do *Cross Validation*

Número do <i>Fold</i>	F1-Score	Precisão	Sensibilidade
1	94,8	95,6	97,2
2	93,1	96,2	95,7
3	96,6	98,0	97,2
4	90,8	94,4	93,3
Média	93,8	95,9	96,2
Desvio padrão	2,4	1,2	2,1

O modelo analisado até agora apresentou algumas predições de falsos positivos, principalmente na região central do coração, onde havia calcificações na aorta, como observado pelas setas vermelhas na Figura 9. Essas calcificações não fazem parte das artérias coronárias, portanto, mesmo sendo calcificações, são falsos positivos que devem ser evitados. Nesse contexto, a terceira etapa do modelo (remoção de falsos positivos) se faz necessária.




Figura 9. Exemplo de segmentação de calcificação: (a) imagem original (b) *ground-truth* e (c) predição

Uma comparação entre o modelo com e sem a terceira etapa (remoção de falsos positivos) pode ser observada na Tabela 5.

Tabela 5. Comparação entre modelo com e sem etapa de remoção de falsos positivos

Modelo	F1-Score	Precisão	Sensibilidade
Sem terceira etapa	96,6	98,0	97,2
Com terceira etapa	96,8	98,3	97,0

Como pode ser observado, houve uma melhora no F1-Score e Precisão devido à remoção de alguns falsos positivos. No entanto, a sensibilidade diminuiu devido à perda de alguns pixels verdadeiros positivos. Apesar da perda de alguns pixels, as calcificações continuam sendo identificadas, mantendo assim o objetivo de segmentá-las. Um exemplo de imagem após a etapa de remoção de falsos positivos pode ser visto na Figura 10. Nessa figura, a presença de

uma calcificação na aorta, indicada pela seta vermelha, não é prevista como uma calcificação pelo modelo, demonstrando a eficácia da etapa de remoção de falsos positivos.




Figura 10. Exemplo de segmentação de calcificação: (a) imagem original (b) *ground-truth* e (c) predição

4.1 Comparação com trabalhos relacionados

Na segmentação de calcificações, o método proposto alcança resultados positivos próximos a outros trabalhos anteriores, como pode ser visto na Tabela 6.

Tabela 6. Métodos na segmentação de calcificação das artérias coronárias

Método	F1-Score	Precisão	Sensibilidade
Föllmer et al. (2022)	92,8	98,4	96,1
Gogin et al. (2021)	97,5	99,5	96,8
Zhang et al. (2019)	95,4	99,1	91,1
Método proposto	96,8	98,3	97,0

O método proposto apresentou métricas próximas às de Gogin et al. (2021). O método dele utiliza 5 U-Nets 3D para votação de segmentação, o que requer alto custo computacional e uma configuração de hardware poderosa, além de utilizar uma arquitetura mais complexa em comparação com o método proposto. Com base nisso, o método proposto superou a métrica de Sensibilidade de Gogin et al. (2021), e aproximou-se na métrica de Precisão. Isso se deve ao uso do *histogram matching*, a arquitetura proposta e uma etapa específica para remoção de falsos positivos. Vale ressaltar que o método proposto também superou o F1-Score de Föllmer et al. (2022) e Zhang et al. (2019).

5. CONCLUSÃO

O estudo teve como objetivo desenvolver um método para segmentar calcificações nas artérias coronárias no conjunto de dados OrcaScore. Vários experimentos foram conduzidos para melhorar os resultados, incluindo pré-processamento, aumento de dados, pós-processamento e exploração de diferentes arquiteturas. Os resultados apresentados são baseados nas métricas de melhor desempenho obtidas até o momento.

Os experimentos utilizando as arquiteturas U-Net modificada e U-Net+EfficientNetB0, juntamente com a extração de ROI, *histogram matching* e remoção de falsos positivos, obtiveram resultados positivos. Vale ressaltar que apenas imagens de exames de CSCT foram utilizadas neste trabalho, excluindo os exames CCTA menos comuns que envolvem contraste. O *histogram matching*, um passo de pré-processamento não utilizado em estudos anteriores, apresentou melhorias significativas nos resultados. Além disso, um passo dedicado de remoção de falsos positivos contribuiu para uma precisão mais alta.

Como trabalhos futuros, sugere-se explorar novas arquiteturas, como blocos de atenção ou redes híbridas com a DeepLab, já que esta utiliza convoluções dilatadas e capturam informações de contextos mais amplos sem aumentar a complexidade computacional, além de apresentar resultados promissores em tarefas de segmentação.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, Fundação de Amparo a Pesquisa do Maranhão (FAPEMA), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e Empresa Brasileira de Serviços Hospitalares (Ebserh) Brazil (Proc. 409593/2021-4).

REFERÊNCIAS

- Chinchor, N. and Sundheim, B.M. (1993). Muc-5 evaluation metrics. In *Fifth Message Understanding Conference (MUC-5): Proceedings of a Conference Held in Baltimore, Maryland, August 25-27, 1993*.
- de Vos, B.D., Wolterink, J.M., Leiner, T., de Jong, P.A., Lessmann, N., and Išgum, I. (2019). Direct automatic coronary calcium scoring in cardiac and chest ct. *IEEE transactions on medical imaging*, 38(9), 2127–2138.
- Föllmer, B., Biavati, F., Wald, C., Stober, S., Ma, J., Dewey, M., and Samek, W. (2022). Active multitask learning with uncertainty-weighted loss for coronary calcium scoring. *Medical Physics*, 49(11), 7262–7277.
- Gogin, N., Viti, M., Nicodème, L., Ohana, M., Talbot, H., Gencer, U., Mekukosokeng, M., Caramella, T., Diascorn, Y., Airaud, J.Y., et al. (2021). Automatic coronary artery calcium scoring from unenhanced-ecg-gated ct using deep learning. *Diagnostic and Interventional Imaging*, 102(11), 683–690.
- Gonzalez, R.C. (2009). *Digital image processing*. Pearson education india.
- Kendall, A., Gal, Y., and Cipolla, R. (2018). Multi-task learning using uncertainty to weigh losses for scene geometry and semantics. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 7482–7491.
- Lin, T.Y., Goyal, P., Girshick, R., He, K., and Dollár, P. (2017). Focal loss for dense object detection. In *Proceedings of the IEEE international conference on computer vision*, 2980–2988.
- Sudre, C.H., Li, W., Vercauteren, T., Ourselin, S., and Jorge Cardoso, M. (2017). Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: Third International Workshop, DLMIA 2017, and 7th International Workshop, ML-CDS 2017, Held in Conjunction with MICCAI 2017, Québec City, QC, Canada, September 14, Proceedings 3*, 240–248. Springer.
- Wang, H., Naghavi, M., Allen, C., Barber, R., Bhutta, Z., Carter, A., et al. (2016). A systematic analysis for the global burden of disease study 2015. *Lancet*, 388(10053), 1459–1544.
- Wang, W., Wang, H., Chen, Q., Zhou, Z., Wang, R., Zhang, N., Chen, Y., Sun, Z., and Xu, L. (2020). Coronary artery calcium score quantification using a

deep-learning algorithm. *Clinical Radiology*, 75(3), 237–e11.

Yoshida, A., Lee, Y., Yoshimura, N., Kuramoto, T., Hasegawa, A., and Kanazawa, T. (2021). Automated heart segmentation using u-net in pediatric cardiac ct. *Measurement: Sensors*, 18, 100127.

Zhang, W., Zhang, J., Du, X., Zhang, Y., and Li, S. (2019). An end-to-end joint learning framework of artery-specific coronary calcium scoring in non-contrast cardiac ct. *Computing*, 101, 667–678.