

Alan de Carvalho Araújo

**Segmentação e classificação automática de
calcificação da artéria coronária em imagem de
tomografia computadorizada utilizando
aprendizado profundo**

São Luís - MA

Fevereiro de 2024

Alan de Carvalho Araújo

Universidade Federal do Maranhão – UFMA

Centro de Ciências Exatas e Tecnologias

Departamento de Engenharia Elétrica

Programa de pós-graduação em Engenharia Elétrica

**Segmentação e classificação automática de calcificação da
artéria coronária em imagem de tomografia
computadorizada utilizando aprendizado profundo**

Dissertação de mestrado apresentada ao programa de pós-graduação em Engenharia Elétrica da Universidade Federal do Maranhão na área de Ciência da Computação, como parte dos requisitos necessários para obtenção do grau de Mestre em Engenharia Elétrica.

São Luís - MA

Fevereiro de 2024

Alan de Carvalho Araújo

Segmentação e classificação automática de calcificação da artéria coronária em imagem de tomografia computadorizada utilizando aprendizado profundo

Dissertação de mestrado apresentada ao programa de pós-graduação em Engenharia Elétrica da Universidade Federal do Maranhão na área de Ciência da Computação, como parte dos requisitos necessários para obtenção do grau de Mestre em Engenharia Elétrica.

Trabalho apresentado em: São Luís - MA, 23 de Fevereiro de 2024.

Prof. Dr. Aristófanês Correa Silva
Orientador

Prof. Dr. João Manuel Pedrosa
Coorientador

Prof. Dr. João Viana da Fonseca Neto
Universidade Federal do Maranhão
Banca Examinadora

Prof. Dr. João Otávio Bandeira Diniz
Instituto Federal de Educação, Ciência e Tecnologia
Banca Examinadora

São Luís - MA
Fevereiro de 2024

Este trabalho é dedicado à minha família.

Agradecimentos

Agradeço primeiramente à Deus por tudo na vida, pela sabedoria, pela saúde e principalmente pelos pais que me deu. Gostaria de agradecer em seguida aos meus pais, José Bernardo e Maria do Socorro, pela educação e pelos ensinamentos que eles me proporcionaram. Agradeço à eles também pelo incentivo que sempre me deram em continuar tentando, nunca desistir por causa de obstáculos e por serem exemplos que sempre me ajudaram a continuar caminhando. Não posso esquecer de agradecer também aos meus irmãos Alexandre e Alana que sempre me auxiliaram na resolução de problemas e nunca recusaram ajuda.

Agradeço também aos professores da Universidade Federal do Maranhão (UFMA) pelos conhecimentos concebidos por eles. Um agradecimento especial para o Professor Aristófanis pela oportunidade e pela confiança dadas à mim para que eu pudesse participar de seu laboratório e pudesse adquirir experiências de valores inestimáveis. Bem como ao Professor João Pedrosa da InescTec.

Agradeço à FAPEMA, CAPES e CNPQ pelos recursos cedidos que foram utilizados para o desenvolvimento dessa monografia. Bem como agradeço ao Núcleo de Computação Aplicada pelo espaço e materiais que foram concebidos para me auxiliar.

No laboratório conheci e agradeço pessoas que foram essenciais para meu desenvolvimento como aluno, são eles: Victor Rogério, Daniel Lima, Saulo Rodrigues, Mário Freitas, Pedro Bernard, João Pedro, Estephane Mendes, Ítalo Ferreira. Foram responsáveis por um conhecimento que não poderia adquirir de outra forma.

Não posso esquecer de agradecer meus amigos próximos, alguns compartilharam experiências comigo desde os primórdios do mestrado e outros foram agregando no caminho, mas todos me ajudaram durante esse período. Gahio Nikolas, Thays Prado, Marcos Maranhão, Luís Matheus, Vitor Nunes, Vinicius Sousa, Guilherme Cutrim, Ian Matheus, Vinicius Midvino, André Ramon, Geovaana, Mário Ricardo, Laila Aranha, Luysa Matos e Cecília Alves.

*Nós almejamos por novas sensações
Mas logo nos tornamos indiferentes à elas.
As maravilhas de ontem
São coisas comuns hoje em dia
(Nikola Tesla)*

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 e classificação de calcificação das artérias coronárias. A tarefa de segmentação possui 4 etapas que são extração da região de interesse utilizando U-Net com *batch normalization* após camadas de convolução, segmentação das calcificações, remoção de falsos positivos utilizando U-Net com EfficientNetB0, e a etapa de classificação que foi realizada com base na região onde foi segmentada a calcificação. 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 na tarefa de segmentação alcançou uma pontuação F1-Score de 96,9%, precisão de 98,5% e sensibilidade de 97,2% na base de imagens de calcificação OrCaScore. Já na tarefa de classificação, o método alcançou uma métrica de coeficiente de correlação intraclasse de 99,0% para todas as classes, e de 95,9%, 95,8% e 97,3% para as classes LAD, LCX e RCA, respectivamente, além de uma Kappa ponderado de 1.

Palavras-chave: Segmentação. Classificação. Calcificação. U-Net. EfficientNetB0.

Abstract

One of the indicators of possible future occurrences of cardiovascular diseases is the amount of coronary arteries calcification. Recently, approaches using new technologies, such as deep learning, have helped to identify these indicators. This work proposes a method for segmenting and classifying coronary artery calcification. The segmentation task has 4 steps that are: extraction of the region of interest using U-Net with batch normalization after convolution layers, segmentation of calcifications, removal of false positives using U-Net with EfficientNetB0, and the classification step which was carried out based on the region where the calcification was segmented. The method uses a histogram matching technique as preprocessing, in order to increase the contrast between tissue and calcification and normalize the different types of exams. Tests were carried out between different architectures where the best approach in the segmentation task achieved an F1-Score rating of 96.9%, accuracy of 98.5% and sensitivity of 97.2% on the OrcaScore calcification dataset. In the classification task, the method achieved an Intraclass Correlation of 99.0% for all classes, and of 95.9%, 95.8% and 97.3% for the LAD, LCX and RCA classes, respectively, in addition to a weighted Kappa of 1.

Keywords: Segmentation. Classification. Calcification. U-Net. EfficientNetB0

Lista de ilustrações

Figura 3.1 – Artérias coronárias.	22
Figura 3.2 – Exemplo de exame de ultrassom de artéria : (a) sem calcificação e (b) com calcificação.	23
Figura 3.3 – Exame de tomografia computadorizada.	24
Figura 3.4 – Exemplo de ANN totalmente conectada.	25
Figura 3.5 – Exemplo de neurônio de uma ANN.	26
Figura 3.6 – Exemplo de camada de convolução 2D de um kernel 3x3 e 5 mapas de características.	29
Figura 3.7 – Exemplo de operação de max pooling.	30
Figura 3.8 – Arquitetura U-Net.	31
Figura 3.9 – Arquitetura U-Net modificada.	32
Figura 3.10–Arquitetura EfficientNet.	32
Figura 4.1 – Fluxograma do método proposto e suas etapas: (1) extração da ROI, (2) Segmentação das calcificações, (3) Remoção de falsos positivos e (4) Classificação das calcificações.	33
Figura 4.2 – Aplicação de <i>histogram matching</i> : (a) imagem original (b) imagem de referência e (c) imagem com histograma modificado.	34
Figura 4.3 – Exemplo da operação morfológica OR: (a) fatia a (b) fatia b e (c) máscara final.	35
Figura 4.4 – Exemplo de operação de abertura: (a) imagem original e (b) imagem resultante.	36
Figura 4.5 – Exemplo de: (a) <i>bounding box</i> após pós-processamentos e (b) ROI extraída na primeira etapa.	36
Figura 4.6 – Arquitetura utilizada na segmentação da calcificação.	37
Figura 4.7 – Exemplo de segmentação de calcificação: (a) fatia de imagem do paciente e (b) predição da rede.	37
Figura 4.8 – Exemplo de pré-processamento da terceira etapa: (a) imagem 512×512 com <i>bounding box</i> em vermelho (b) <i>bounding box</i> redimensionada para 96×96 e (c) ROI de tamanho 96×96 extraída no pré-processamento.	38
Figura 4.9 – Exemplo de: (a) imagem de dimensão 96×96 e (b) imagem de saída da terceira etapa de dimensão 512×512	39
Figura 4.10–Exemplos de classificação da classe: (a) LAD (b) LAD e LCX e (c) RCA.	40
Figura 4.11–Divisão dos quadrantes do coração por classe: 1º Quadrante é da classe LAD, 2º quadrante é da classe RCA, 3º quadrante é da classe fundo e 4º quadrante é da classe LCX.	40

Figura 4.12–Exemplos do processo para classificação de calcificação: (a) Fatia N do paciente P (b) segmentação do coração da fatia N (c) divisão do coração em quadrantes (d) quadrantes na fatia N e (e) posição de cada calcificação nos quadrantes	41
Figura 5.1 – Exemplos de extração da ROI na base OrCaScore: (a) Fatia original paciente 1 (b) Fatia original paciente 2 (c) Fatia original paciente 3 (d) ROI extraída do paciente 1 (e) ROI extraída do paciente 2 e (f) ROI extraída do paciente 3	47
Figura 5.2 – Exemplos de ROI extraídas : (a) paciente 1 (método proposto) (b) paciente 2 (método proposto) (c) paciente 3 (método proposto) (d) paciente 1 (YOLOv8) (e) paciente 2 (YOLOv8) e (f) paciente 3 (YOLOv8)	48
Figura 5.3 – Exemplo de segmentação de calcificação: (a) imagem original (b) <i>ground-truth</i> e (c) predição	51
Figura 5.4 – Exemplo de segmentação de calcificação: (a) imagem original (b) <i>ground-truth</i> e (c) predição	52
Figura 5.5 – Exemplo de divisão dos quadrantes do coração: (a) Baseada na <i>bounding box</i> da máscara final e (b) baseada na segmentação do coração da fatia correspondente	53
Figura 5.6 – Comparação das matrizes de confusão: (a) Baseada na <i>bounding box</i> da máscara final e (b) baseada na segmentação do coração da fatia correspondente	53
Figura 5.7 – Matriz de confusão do score de Agatston	54

Lista de tabelas

Tabela 2.1 – Visão geral dos trabalhos relacionados	21
Tabela 3.1 – Graus de risco de DAC de acordo com o escore de Agatston	24
Tabela 5.1 – Comparação de arquiteturas para extração da ROI	46
Tabela 5.2 – Comparação de modelos para extração da ROI	47
Tabela 5.3 – Comparação entre imagens com e sem <i>histogram matching</i> com as ROIs extraídas pelos dois métodos	48
Tabela 5.4 – Comparação entre modelos e funções de perdas	49
Tabela 5.5 – Comparação de segmentação da calcificação utilizando ROI extraída pelos dois modelos	49
Tabela 5.6 – Comparação entre arquiteturas na segmentação de calcificação	50
Tabela 5.7 – Resultados da validação cruzada	50
Tabela 5.8 – Comparação do método com e sem a etapa de remoção de falsos positivos	51
Tabela 5.9 – Comparação entre arquiteturas na remoção de falsos positivos	52
Tabela 5.10–Métrica ICC para cada artéria e todas as artérias	54
Tabela 5.11–Comparação entre métodos de segmentação da calcificação na artéria coronária	55
Tabela 5.12–Comparação entre métodos de classificação da calcificação na artéria coronária utilizando métrica ICC	56

Lista de abreviaturas e siglas

ANN	Redes Neurais Artificiais (do inglês, <i>Artificial Neural Network</i>)
CACS	Escore de Calcificação Arterial Aoronariana (do inglês, <i>Coronary Arterie Calcification Score</i>)
CCTA	Angiografia Coronariana (do inglês, <i>Coronary Computed Tomography Angiography</i>)
CCTA	Rede Neural Convolutcional (do inglês, <i>Convolutional Neural Network</i>)
CT	Tomografia Computadorizada (do inglês, <i>Computed Tomography</i>)
DAC	Doenças Arterial Coronariana
DIC	Doenças Isquêmica do Coração
HU	Unidades Hounsfield (do inglês, <i>Hounsfield Units</i>)
IA	Inteligência Artificial
ICC	Coeficiente de Correlação Intraclassa (do inglês, <i>Intraclass Correlation coefficient</i>)
LAD	Artéria Coronária Descendente Esquerda (do inglês, <i>Left Anterior Descending</i>)
LCA	Artéria Coronária Esquerda (do inglês, <i>Left Coronary Artery</i>)
LCX	Artéria Coronária Circunflexa (do inglês, <i>Left Circunflex Artery</i>)
ML	Aprendizado de Máquina (do inglês, <i>Machine Learning</i>)
MSE	Erro Médio Quadrado (do inglês, <i>Mean Square Error</i>)
MSWM	Quadrado Médio Das Medidas (do inglês, <i>Mean Square Within Meas-urements</i>)
MSWS	Quadrado Médio Das Materias (do inglês, <i>Mean Square Within Subjects</i>)
RCA	Artéria Coronária Direita (do inglês, <i>Right Coronary Artery</i>)
RELU	Unidade Linear Retificadora (do inglês, <i>Rectified Linear Unit</i>)
ROI	Região de Interesse (do inglês, <i>Region Of Interest</i>)

Sumário

1	INTRODUÇÃO	14
1.1	Objetivos	16
1.1.1	Objetivo Geral	16
1.1.2	Objetivos Específicos	16
1.2	Organização do trabalho	17
2	TRABALHOS RELACIONADOS	18
3	FUNDAMENTAÇÃO TEÓRICA	22
3.1	Calcificações coronárias	22
3.2	Aprendizado Profundo	25
3.2.1	Redes neurais artificiais	25
3.2.2	Neurônios	26
3.2.3	Função de ativação	27
3.2.4	Função de perda	27
3.2.5	Rede Neural Convolucional	28
3.2.6	U-Net	30
3.2.7	EfficientNet	31
4	MÉTODO	33
4.1	Extração da ROI	33
4.1.1	Pré-processamento	34
4.1.2	Arquitetura utilizada	35
4.1.3	Pós-processamento	35
4.2	Segmentação da calcificação	37
4.3	Remoção de falsos positivos	38
4.3.1	Pré-processamento	38
4.3.2	Pós-processamento	39
4.4	Classificação das calcificações	39
4.5	Métricas de avaliação	41
5	RESULTADOS E DISCUSSÃO	44
5.1	Base de imagens	44
5.1.1	Base de imagens CT Heart	44
5.1.2	Base de imagens OrCaScore	44
5.1.3	Base de imagens própria	45

5.2	Configuração dos experimentos	45
5.3	Experimentos	46
5.3.1	Extração da ROI	46
5.3.2	Segmentação da calcificação	47
5.3.3	Remoção de falsos positivos	51
5.3.4	Classificação das calcificações	53
5.4	Comparação com trabalhos relacionados	55
6	CONCLUSÃO	57
	REFERÊNCIAS	59

1 Introdução

A doença arterial coronariana (DAC) é uma das principais doenças cardiovasculares, cuja prevalência aumenta a cada ano. A DAC obstrutiva é uma das principais causas de morte em países desenvolvidos e em desenvolvimento (SHINOHARA et al., 2021). Aproximadamente 19 milhões de mortes ocorreram na população mundial no ano de 2020 devido à DAC (TSAO et al., 2023), o que é um aumento de 18,71% em relação à 2010. No geral, a prevalência DAC foi de 607,64 milhões de casos em 2020, um aumento de 29,01% em comparação com 2010 (TSAO et al., 2023).

No Brasil, principalmente doenças coronarianas, têm sido a principal causa de morte há meio século (RIBEIRO et al., 2016). O risco de morte ajustado à idade por doenças cardíacas ateroscleróticas e doenças cerebrovasculares aumentou desde a década de 1940 (LOTUFO; BENSEÑOR, 2009). Em 2019, 27% das mortes foram atribuídas às doenças cardiovasculares (BICHARA et al., 2023). O Brasil teve uma média de 306 mortes diárias por doenças cardiovasculares, ou uma morte a cada cinco minutos (DATASUS, 2018). A doença cardíaca coronária, agora a principal causa de morte por doenças cardiovasculares, foi responsável por 31% da mortalidade por doenças cardiovasculares (BICHARA et al., 2023).

A presença de calcificação na artéria coronária avaliada por tomografia computadorizada (TC) é um indicador confiável de DAC e é comumente usada como um importante biomarcador para prever o risco de um evento grave de DAC (WANG et al., 2020). Estudos estabeleceram que o escore de calcificação da TC auxilia na predição de risco (HECHT, 2014). O escore é mais preditivo do que qualquer outro biomarcador único, incluindo lipídios (MARTIN et al., 2014).

A avaliação do escore de calcificação arterial coronariano (CACS) por meio de TC evoluiu, portanto, para ser uma ferramenta aceitável para estratificação de risco cardiovascular (MORI et al., 2018). Com inovações na área, a quantificação da calcificação da artéria coronária e a imagem da artéria coronária com o uso da angiotomografia coronária (CCTA) tornaram-se amplamente disponíveis na prática clínica para a avaliação da DAC (BLAHA et al., 2017). A quantificação do escore de cálcio da TC é usada principalmente como uma ferramenta de estratificação de risco de doença cardiovascular em indivíduos assintomáticos; entretanto, a desvantagem do método como teste de triagem é o risco de radiação a ele associado (WANG et al., 2020).

Atualmente, a imagem do escore de cálcio por TC como teste de triagem em indivíduos saudáveis, *a priori*, tornou-se predominante em ambientes clínicos (WANG et al., 2020). Diretrizes recentes e consenso de especialistas recomendam a varredura e

medição do CACS antes do CCTA (HECHT et al., 2017). A quantificação do CACS ainda requer medição manual, que é um trabalho demorado e trabalhoso. Além disso, o valor também pode variar entre observadores com diferentes experiências. Portanto, uma avaliação automatizada pode ser benéfica.

A inteligência artificial (IA) é cada vez mais utilizada em radiologia diagnóstica e medicina, pois fornece diagnóstico reproduzível e objetivo, extraindo características relevantes dos dados de imagens médicas e usando-as em classificadores para detecção automatizada de doenças cardiovasculares, servindo assim como uma valiosa ferramenta auxiliar na clínica prática (ACHARYA et al., 2014). O algoritmo de aprendizado de máquina ou aprendizado profundo é um subconjunto de IA que utiliza algoritmos para combinar dados volumosos que compreendem informações clínicas e variáveis anatômicas coronarianas para predição ideal de eventos cardíacos. O processo usando IA para quantificar CACS seria adequado para aprender e recuperar atributos multidimensionais (DEY et al., 2018).

Devido aos desenvolvimentos nas tecnologias de imagem que permitiram a captura e armazenamento de grandes quantidades de dados, a IA atraiu enorme atenção e ofereceu novas abordagens para aproveitar o volume crescente de dados de imagem disponíveis para análise. Tais abordagens foram aplicadas com sucesso em imagens médicas para melhorar a quantificação, destacar achados sutis que um médico poderia não perceber, ajudar na classificação patológica e fornecer recomendações para acompanhamento (DILSIZIAN; SIEGEL, 2018).

No que diz respeito à imagem cardiovascular, a IA pode ser particularmente útil para lidar com a otimização da aquisição de imagens, ajudando no pós-processamento de imagens que requer cada vez mais tempo e habilidade à medida que os testes de imagem se tornam amplamente disponíveis e o número de características analisadas aumenta exponencialmente, e em desenvolvimento de novos biomarcadores prognósticos para avaliação de risco. Há uma literatura crescente sobre o potencial e o uso da IA na TC cardíaca (MONTI et al., 2020).

Alguns estudos anteriores exploraram a detecção automática de DAC obstrutiva baseada em IA (HAN et al., 2020). Estudos sobre o desempenho diagnóstico da IA na detecção automática de estenose coronária obstrutiva em imagens de CCTA mostraram que a precisão diagnóstica da CCTA baseada em IA era melhor do que a CCTA tradicional sozinha (HAN et al., 2020). Thilo et al. (2015) avaliaram o efeito de um algoritmo de detecção auxiliado por computador para CCTA no desempenho de leitores com diferentes níveis de experiência.

O aprendizado de máquina (ML) é um campo da IA no qual os modelos são construídos com base em conjuntos de dados de treinamento que geram previsões para conjuntos de dados novos e potencialmente grandes, sem treinamento específico. O aprendizado profundo representa um campo de ML que explora redes neurais artificiais. Estas

podem ser definidas como redes neurais profundas (DNN) quando múltiplas camadas são utilizadas para prever uma saída de uma determinada entrada (MOTWANI et al., 2017).

Portanto a avaliação manual do escore de cálcio é uma tarefa demorada e trabalhosa. Neste contexto, uma avaliação automática desse escore pode ser benéfico tanto para o médico quanto para o paciente, de forma a auxiliar no diagnóstico, além de acelerar esse processo, tornando-os mais rápido e precisos.

1.1 Objetivos

Nesta seção serão descritos o objetivo geral e os objetivos específicos.

1.1.1 Objetivo Geral

O objetivo geral deste trabalho é propor um método para segmentação e classificação automática de calcificações nas artérias coronárias em imagens de tomografia computadorizada, dividindo esse processo em etapas e usando redes neurais convolucionais.

1.1.2 Objetivos Específicos

Para atingir o objetivo principal deste trabalho, foi necessário atingir os seguintes objetivos específicos:

- Desenvolver um método computacional para localização e extração de uma região de interesse (ROI);
- Produzir um método computacional para geração de mapas de segmentação de calcificações nas artérias coronárias;
- Elaborar uma etapa de refinamento das predições de forma a remover predições falso positivas;
- Realizar análises comparativas entre arquiteturas de rede utilizadas e outras utilizadas no âmbito da segmentação em imagens médicas; e
- Efetuar uma análise comparativa entre o método proposto e métodos utilizados na literatura, além de pontuar pontos fortes e limitações.

1.2 Organização do trabalho

A organização desse trabalho está dividida em seis capítulos, sendo:

Capítulo 2 - Trabalhos Relacionados - capítulo dedicado a apresentar os trabalhos relacionados ao tema investigado, descrevendo seus métodos e resultados obtidos.

Capítulo 3 - Fundamentação Teórica - neste capítulo, é explicado e abordado trabalhos relacionados ao tema, além dos conceitos necessários para a compreensão dos resultados e da metodologia. Nele é explicado os conceitos sobre calcificações na artéria coronária, exames de tomografia computadorizada, inteligência artificial, aprendizado de máquina e aprendizado profundo.

Capítulo 4 - Materiais e método - neste capítulo, são descritos os passos necessários para desenvolver e implementar o método em cascata de segmentação e classificação da artéria coronária, além de explicar o funcionamento e o desenvolvimento de cada passo.

Capítulo 5 - Resultados e Discussão - neste capítulo, são apresentados os resultados obtidos mediante a implementação do método, além de comparações com outras arquiteturas e outros métodos

Capítulo 6 - Conclusão - capítulo dedicado a apresentar as considerações finais sobre o método proposto, além de descrever possíveis trabalhos futuros.

2 Trabalhos Relacionados

Este capítulo apresenta os trabalhos relacionados utilizados como referência para o desenvolvimento deste estudo. Os trabalhos aqui mencionados dizem respeito ao processo de segmentação e classificação das calcificações nas artérias coronárias em exames de tomografia computadorizadas utilizando aprendizado profundo.

Em (VOS et al., 2019) é proposto um método automático para escore direto de cálcio em TC cardíaca e TC de tórax. O método utiliza duas ConvNets, uma para registro de atlas para alinhar o campo de visão (FOV) de imagens de entrada a uma imagem de atlas feita de TCs cardíacas e outro para escore direto de cálcio de fatias de imagem de entrada usando regressão. O método alcança precisão de 87,0%, sensibilidade de 95,0%, F1-Score de 91,0% e ICC de 98,0%. A principal vantagem desse método é a velocidade para realizar todo o processo, enquanto algumas métricas como precisão não são tão elevadas em relação as outras.

Em (ZHANG et al., 2019) é empregado uma DenseRAUnet, que combina uma Dense U-Net, ResNet e convolução dilatada. As imagens são pré-processadas redimensionando-as para 512×512 pixels. A função de perda é uma Dice Loss multiclasse para equilibrar efetivamente a classe de fundo e a classe de calcificação. O modelo é treinado em tomografias computadorizadas torácicas sem contraste em uma abordagem 2.5D e avaliado em tomografias computadorizadas cardíacas. Os resultados mostram um F1-Score de 95,4% e uma precisão de 99,1%. Porém, este método não apresenta resultados em objetos pequenos (calcificações menores) tão bons quanto em objetos maiores (calcificações grandes).

Velzen et al. (2020) propuseram um método que consiste em duas CNNs. A primeira CNN possui um grande FOV e detecta candidatos a calcificações na imagem e os rotula de acordo com sua localização anatômica. A segunda CNN tem um FOV menor e detecta verdadeiras calcificações entre os candidatos detectados pela primeira CNN. Este método alcançou um ICC de 99,0%.

Enquanto (MARTIN et al., 2020) propuseram um estudo sobre avaliação automática de algoritmo de escore de cálcio coronariano baseado em aprendizagem profunda com dados de 511 pacientes de 2014 a 2018. Todos os dados foram coletados em um tomógrafo de fonte dupla (SOMATOM Force, Siemens Healthineers, Erlangen, Alemanha). A análise automatizada de cálcio baseada em aprendizado profundo foi realizada utilizando uma rede neural com arquitetura ResNet e uma rede neural totalmente conectada para funções de coordenadas espaciais. Eles usaram unidades Hounsfield e treinaram em 2.000 imagens. A precisão foi decidida de acordo com o CACS. Quando foi (0, 1–10, 11–100, 101–400 e >400), a precisão foi (94,9%, 73,5%, 95,6%, 98,3% e 92,3%), respectivamente. A limitação

deste trabalho é que a maioria dos dados consiste em dados de indivíduos normais sem calcificação.

Por outro lado, (OEVER et al., 2020) propuseram uma abordagem que emprega uma U-Net com convoluções dilatadas para segmentar CAC analisando fatias de imagem em três direções ortogonais e, a partir daí, combina-as para obter a segmentação final. A avaliação mostrou que, devido à ausência de previsões de falsos negativos (sensibilidade de 100%), o método poderia ser utilizado para excluir exames sem CAC para aliviar a carga de trabalho do radiologista. Contudo, os exames no teste não possuíam pacientes com escore de Agatston < 10 e também não possui um tratamento para os falsos positivos, levando à precisão de 88,9%.

Em (GOGIN et al., 2021) é proposto um método que utiliza um conjunto de cinco redes neurais convolucionais (CNN) com arquitetura U-Net 3D treinadas em um banco de dados de 783 exames de TC para detectar e segmentar calcificações de artérias coronárias em um volume 3D. O escore de Agatston foi calculado fatia por fatia. A qualidade da estimativa foi avaliada com o índice de concordância (índice C) na categoria de risco de CAC num conjunto de testes separado de 98 exames de TC independentes. Este trabalho alcançou ótimas métricas como F1-Score de 97,5% e um ICC de 99,5%. Entretanto esse método não utiliza nenhum tipo de pré-processamento de forma a auxiliar na identificação das calcificações.

Em contrapartida, (LEE et al., 2021) três modelos de CNN são aplicados para um total de 2.400 imagens de pacientes, onde 1.200 são imagens de TC cardiovasculares normais e 1.200 são imagens de TC nas quais o cálcio está presente no sistema cardiovascular. Foi realizado o teste experimental classificando os dados da imagem de TC nas imagens originais de TC do escore de cálcio da artéria coronária contendo toda a caixa torácica, as imagens cardíacas segmentadas que cortam apenas a região do coração e as imagens cardíacas recortadas que são criadas usando as imagens cardíacas que são segmentadas em nove subpartes e ampliadas. Entretanto, são apenas sinalizados as fatias de imagens que possuem cálcio, e não é feita uma avaliação do escore de cálcio, dificultando a triagem do grau de risco do paciente.

Em (MU et al., 2022) é proposto um método de detecção de cálcio e um módulo de regressão de pontuação CAC, ambos utilizando CNNs 3D. O módulo de detecção de cálcio gera uma máscara de região de cálcio usando um codificador multiresolução e estrutura decodificadora com conexões de salto, semelhante ao U-Net. O método alcançou um ICC de 96,0%.

Em contraste, (FÖLLMER et al., 2022) introduz um modelo multitarefa para 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 perda de incerteza ponderada.

O método proposto alcançou um escore F1 de 92,8% para a tarefa de segmentação de calcificação. Porém, este método não tem como mitigar as diferenças nos exames realizados em diferentes tomógrafos, o que dificulta o processo de aprendizagem do modelo.

Ihdayhid et al. (2023) implementam uma abordagem que consiste na utilização de 2 CNNs para segmentar o coração e a aorta em imagem de TC. Em seguida utiliza uma 3D CNN que combina seis canais de entrada, cada um representando um subvolume 3D. Destes seis canais de entrada, dois são usados para segmentação da aorta e do coração, e outros três para fornecer contexto espacial relativo ao centro da varredura nas direções x, y e z. O canal final representa o subvolume da unidade Hounsfield (HU). Desta forma, alcançaram um F1-score de 96,6% e um ICC de 98,8%.

Assim como alguns dos trabalhos mencionados, o método proposto pelo presente trabalho utiliza CNNs 2D para realizar a segmentação das calcificações. No entanto, diferentemente deles, este método proposto é dividido em etapas considerando as características específicas de cada situação de forma a utilizar uma melhor estratégia para cada etapa. Assim na primeira etapa utilizou-se um pré-processamento para normalizar os diversos tipos de exames de TC, além de aumentar o contraste entre tecidos duros e moles. Também utilizou-se uma U-net com *batch normalization* após camadas de convoluções para extrair uma região de interesse (ROI) por apresentar bom desempenho em segmentação de órgãos em TC. Na segunda etapa utilizou-se uma U-Net com a EfficientNetB3 para segmentar as calcificações. Já na terceira etapa, utilizou-se uma estratégia e uma arquitetura de rede, similar à da segunda etapa, para remover falsos positivos.

Na Tabela 2.1, pode-se ver um resumo dos trabalhos relacionados mencionados neste capítulo, apontando os autores, técnicas utilizadas e base de imagens.

Tabela 2.1 – Visão geral dos trabalhos relacionados

Trabalhos relacionados	métodos utilizados	base de imagens
(VOS et al., 2019)	Duas ConvNets (Registro e escore de cálcio)	OrCaScore
(ZHANG et al., 2019)	DenseRAUnet (2.5D)	Base privada de Beijing Hospital
(VELZEN et al., 2020)	Duas CNNs (Uma com grande FOV) (1 com FOV menor)	Base privada
(MARTIN et al., 2020)	ResNet CNN para coordenadas espaciais	Base privada
(OEVER et al., 2020)	U-Net + convoluções dilatadas	Base privada
(GOGIN et al., 2021)	Cinco U-Net 3D	SFR 2020 Data OrCaScore
(LEE et al., 2021)	Três CNNs (ResNet50, ResNet-v2, VGG19)	Base privada Soonchunhyang Hospital
(MU et al., 2022)	Duas U-Net 3D	Base privada Nanjing Hospital
(FÖLLMER et al., 2022)	CNN + multitask Learning	Discharge OrCaScore CADMAN
(IHDAYHID et al., 2023)	Duas CNNs 2D e 1 CNN 3D	Base privada Envision Medical Imaging
Método proposto	Três CNNs 2D Método em cascata (4 etapas)	OrCaScore

Fonte: Autoral.


3 Fundamentação Teórica

Este capítulo apresenta os conceitos relacionados a calcificações coronárias, uso de aprendizado profundo para segmentação e classificação de doenças em imagens médicas, necessários para o bom entendimento do trabalho desenvolvido.

3.1 Calcificações coronárias

As artérias coronárias são os vasos sanguíneos localizados ao redor do coração que fornecem sangue ao miocárdio. A artéria coronária direita (do inglês, *Right Coronary Artery*, RCA) e a artéria coronária esquerda (do inglês, *Left Circunflex Artery*, LCA) originam-se da aorta logo acima de onde sai da câmara ventricular esquerda. A LCA ramifica-se posteriormente na artéria coronária circunflexa esquerda (LCX) e na artéria coronária descendente anterior esquerda (do inglês, *Left Anterior Descending*, LAD) (FILIPOIU, 2013). Observa-se na Figura 3.1 a posição das artérias em relação ao coração.

Figura 3.1 – Artérias coronárias.



Fonte: (CHAKLADAR et al., 2017) ADAPTADA.


Doença arterial coronariana (DAC), também chamada de doença isquêmica do coração, é uma doença que pode causar angina (dor no peito), infarto do miocárdio (ataque cardíaco) e parada cardíaca (NABEL; BRAUNWALD, 2012). DAC é a principal causa de morte em todo o mundo. DAC é causado pela formação de placa ao longo do tempo, onde esta é composta por depósitos de lipídios gordurosos, colesterol, cálcio e outras substâncias

encontradas na corrente sanguínea. Esses depósitos fazem com que as artérias se estreitem e endureçam, também conhecido como aterosclerose.

O estreitamento faz com que o coração não receba sangue rico em oxigênio suficiente, o que leva à angina e ao infarto do miocárdio. Partes severamente estreitadas podem causar coágulos sanguíneos que podem levar à parada cardíaca devido à súbita falta de oxigênio fornecido ao músculo cardíaco. Os fatores de risco incluem genética, diabetes, tabagismo, obesidade, falta de exercício e estresse (NABEL; BRAUNWALD, 2012).

O diagnóstico de DAC pode ser realizado de diversas maneiras. O ecocardiograma é baseado no uso de ultrassom para monitorar os batimentos cardíacos. Se for observado movimento cardíaco irregular, pode ser um sintoma de que o coração não está recebendo sangue suficiente causado pela DAC (BARSNESS; HOLMES, 2011). É possível observar na Figura 3.2 exemplos de artéria sem calcificação e com calcificação no exame de ultrassom. Adventícia, íntima e média são as três camadas que compõe uma artéria, enquanto na Figura 3.2b é possível ver a placa (acúmulo de cálcio), o cateter de IVUS (Ultrassom Intra-Coronário) e o vaso sanguíneo que nesse caso é a artéria coronária.


Figura 3.2 – Exemplo de exame de ultrassom de artéria : (a) sem calcificação e (b) com calcificação.



Fonte: (MELO, 2017) ADAPTADA.

Outro método é o uso da Tomografia Computadorizada. Isso também pode ser usado em combinação com a angiografia coronária invasiva, onde um cateter é inserido nas partes proximais das artérias coronárias e o fluido de contraste é então injetado a partir do cateter. Ao fazer isso, as artérias coronárias são mais fáceis de observar e torna possível observar o fluxo sanguíneo para detectar mais facilmente vasos estreitados. Contudo, o fluido de contraste pode causar calor no corpo, leve aceleração dos batimentos cardíacos, náuseas, vômitos e raramente alergias graves (BARSNESS; HOLMES, 2011). Exemplo de exame de tomografia computadorizada de artéria com calcificação pode ser visto na Figura 3.3, bem como outras estruturas que podem ser vistas nesse exame.

Figura 3.3 – Exame de tomografia computadorizada.



Fonte: Autoral.

O tratamento inclui mudanças no estilo de vida, medicamentos e, em alguns casos, angioplastia e cirurgias de ponte de safena (RIBEIRO et al., 2016). Na angioplastia, um pequeno cateter com um *stent* em forma de balão é inserido na região estenosada para remover a placa. Nas cirurgias de ponte de safena, uma nova artéria é estendida da aorta e inserida cirurgicamente além da passagem bloqueada (RIBEIRO et al., 2016).

Na prática clínica, a quantidade de calcificação na artéria coronária (CAC) é estimada pelo escore de Agatston (AGATSTON et al., 1990), que foi amplamente validado em diversos estudos para estimar o risco cardiovascular. O escore de Agatston é calculado a partir de componentes conectados axiais bidimensionais (2D) acima de 130 unidades Hounsfield (HU) que são identificados manual ou semiautomaticamente como calcificação coronariana pelo radiologista. Além do tempo gasto, isso expõe a variabilidade de medição dependendo da experiência do especialista. De acordo com várias diretrizes, esta pontuação é uma ferramenta confiável para classificar pacientes em 4 categorias para avaliação de risco e para orientar estratégias e testes preventivos de acompanhamento (VALENSI et al., 2021) como pode ser visto na Tabela 3.1.

Tabela 3.1 – Graus de risco de DAC de acordo com o escore de Agatston

Escore de Agatston	Grau de severidade
0	Sem evidências de DAC
1-100	Leve risco de DAC
101-400	Risco moderado de DAC
>401	Alto risco de DAC

Fonte: Autoral

3.2 Aprendizado Profundo


O aprendizado profundo é uma forma de aprendizado de máquina que lida com redes neurais artificiais (ANN) contendo múltiplas camadas. Nesta seção, os fundamentos da ANN são explicados, começando com os blocos de construção, conceitos e por fim explicando as redes neurais convolucionais executadas em imagens.

3.2.1 Redes neurais artificiais

Uma ANN é um método que recebe uma série de entradas, como valores de pixel em uma imagem, e produz alguma saída, por exemplo, uma previsão de qual órgão pode ser visto na imagem. Mais especificamente, elas consistem em duas ou mais camadas conectadas entre si, onde cada conexão possui um parâmetro de peso que pode ser aprendido.

Na Figura 3.4 é possível observar uma rede *feed-forward* simples com uma camada de entrada, duas camadas ocultas e uma camada de saída. Cada camada consiste em vários neurônios que recebem entradas de todos os neurônios da camada anterior e enviam saídas para todos os neurônios da próxima camada. Isso é chamado de camada totalmente conectada. A ANN pode ter qualquer número de camadas ocultas e cada camada pode ter qualquer número de neurônios.

Figura 3.4 – Exemplo de ANN totalmente conectada.



Fonte: Autoral.

3.2.2 Neurônios

A entrada para um neurônio na camada l é a soma das saídas y_{l-1} da camada anterior multiplicada pelos pesos w_l^i , onde i é o índice do neurônio. Para obter a saída um bias w_l^i é adicionado e uma função de ativação não linear é usada no resultado para produzir a saída w_l^i . Isso pode ser representado pela Equação 2.1, onde N_l é o número de neurônios na camada l .

$$y_l^i = \sigma\left(\sum_{j=1}^{N_{l-1}} y_{l-1}^j w_l^{j,i} + b_l^i\right) \quad (3.1)$$


A soma na Equação 3.1 também pode ser representada como o produto escalar do vetor y_{l-1} e w_l^i , resultando na Equação 3.2.

$$y_l^i = \sigma((y_{l-1})^T w_l^i + b_l^i) \quad (3.2)$$

O vetor de saída da camada l pode ser representado pela Equação 3.3, onde $W_l - 1$ é uma matriz N_{l-1} por N_l .

$$y_l = \sigma((y_{l-1})^T w_l + b_l) \quad (3.3)$$

Figura 3.5 – Exemplo de neurônio de uma ANN.



Fonte: Autoral.

O processo pode ser representado pela Figura 3.5, onde x representam as entradas, w representam os pesos, b é o bias, e σ é a função de ativação.

3.2.3 Função de ativação

As operações descritas anteriormente são lineares, de forma que, por mais complexa que seja a rede neural, ela só será capaz de captar relações lineares entre as variáveis de entrada e saída. De forma a tornar o modelo capaz de estabelecer relações não-lineares, os resultados de cada camada são processados pelas funções de ativação (APICELLA et al., 2021).

A principal razão pelas quais as funções de ativação são utilizadas, portanto, é para conferir essa capacidade não-linear ao processamento realizado pelas redes neurais. Isso é especialmente importante nas camadas escondidas da rede neural. Nas camadas de saída, as funções de ativação podem ter finalidades específicas, dependendo do objetivo da rede neural (APICELLA et al., 2021).

As escolhas possíveis para a função de ativação σ incluem sigmóide, tanh, ReLU e outras. A maioria das arquiteturas modernas usa alguma variação da função de ativação da unidade linear retificadora (ReLU). A ReLU é definida pela Equação 3.6 (GLOROT; BORDES; BENGIO, 2011).

$$\sigma = \begin{cases} 0 & : x < 0 \\ x & : x \geq 0 \end{cases} \quad (3.4)$$

Um dos primeiros estudos que mostraram melhorias de desempenho de redes equipadas com funções de ativação baseadas em retificadores foi (GLOROT; BORDES; BENGIO, 2011), onde modelos com funções de ativação ReLU melhoraram o desempenho se comparados a redes com unidades sigmóides. O principal benefício do uso de funções de ativação retificadas é evitar o problema do gradiente de fuga, que tem sido um dos principais problemas para redes profundas por muitos anos (APICELLA et al., 2021).

3.2.4 Função de perda

As funções de perda medem quão bem um modelo pode aproximar o resultado desejado e são usadas durante o treinamento para otimizar os parâmetros do modelo. Elas medem a diferença entre os resultados previstos e esperados do modelo, e o objetivo do treinamento é minimizar essa diferença (TERVEN et al., 2023).

A Dice Loss é usada para avaliar a similaridade entre a máscara de segmentação prevista e o *ground-truth*. Essa função de perda é amplamente utilizada em imagens médicas, onde o objetivo é segmentar estruturas como por exemplo órgão em exames de tomografia. A Dice Loss é definida como (TERVEN et al., 2023):

$$D = 1 - \frac{2 \times \text{interseção}(\text{pred}, \text{gt})}{|\text{pred}| + |\text{gt}|} \quad (3.5)$$

Onde $interseção(pred, gt)$ representa o número de pixels na interseção entre a máscara prevista e a máscara do *ground-truth*, $|pred|$ e $|gt|$ representam o número total de pixels da máscara de segmentação prevista e do *ground-truth*, respectivamente.

A Focal Loss é uma variação da Cross Entropy Loss padrão que aborda a questão do desequilíbrio de classes, que ocorre quando o número de amostras positivas (objetos de interesse) é muito menor que o número de amostras negativas (fundo). Nesses casos, o modelo tende a focar nas amostras negativas e negligenciar as amostras positivas, levando a um desempenho ruim. A Focal Loss resolve esse problema diminuindo o peso das amostras negativas fáceis e aumentando o peso das amostras positivas difíceis. A Focal Loss é definida como (LIN et al., 2017):

$$FL(p_t) = -\alpha_t(1 - p_t)^{\gamma} \log(p_t) \quad (3.6)$$

Onde p_t é a probabilidade prevista para a classe positiva, γ_t é fator de peso que controla a importância de cada amostra e γ_t é um parâmetro de foco que controla a taxa na qual exemplos fáceis são reduzidos.

3.2.5 Rede Neural Convolutacional

As redes neurais convolucionais (CNN) introduzem a camada convolutacional e são semelhantes às redes neurais totalmente conectadas apresentadas anteriormente. Ambos consistem em neurônios, pesos que podem ser aprendidos, usam função de perda e podem ser treinados usando os mesmos conceitos (KJERLAND, 2017). Eles diferem na forma como os pesos e resultados são construídos, onde as camadas convolucionais são capazes de explorar as informações espaciais encontradas nas imagens. Uma CNN típica é composta de várias camadas sequenciais conectadas por pesos que atuam como núcleos de filtros convolucionais (KAMNITSAS et al., 2016).


Cada camada $l \in [1, L]$ contém C_l mapas de características. Nas CNN 2D, os mapas de características são grades 2D de neurônios que detectam características do mapa de características da camada anterior. Sendo $K_l^{m,n}$, o kernel, uma matriz de pesos aprendidos $W_l^{m,n}$ do n -ésimo mapa de características na camada anterior ao m -ésimo mapa de característica na camada l . As ativações do m -ésimo mapa de características na l -ésima camada pode ser representado pela Equação 3.8, onde $*$ representa a convolução (KAMNITSAS et al., 2016).

$$y_l^m = \sigma\left(\sum_{n=1}^{C_{l-1}} K_l^{m,n} * y_{l-1}^n + b_l^m\right) \quad (3.7)$$

Essa equação representa a soma dos resultados da convolução de cada mapa de características da camada anterior pelo Kernel 2D. Para obter todas as ativações, os

kernels são deslizados através dos mapas de características, o que significa que todos os neurônios no m -ésimo mapa de característica da l -ésima camada compartilharão os mesmos pesos $W_l^{m,n}$. Todos os mapas de características de uma mesma camada tem as mesmas dimensões, e todos os kernels tem os mesmos tamanhos. Percebe-se na Figura 3.6 um exemplo de convolução entre os kernels e os mapas de características.

Figura 3.6 – Exemplo de camada de convolução 2D de um kernel 3x3 e 5 mapas de características.



Fonte: (KJERLAND, 2017).


Além disso, as CNN possuem as camadas de *Pooling*. Geralmente as camadas de *Pooling* vem em seguida as camadas de convolução. O *pooling* é uma etapa fundamental em sistemas baseados em convolução que reduz a dimensionalidade dos mapas de características. Combina um conjunto de valores em um número menor de valores, ou seja, a redução na dimensionalidade do mapa de características. Ele transforma a representação conjunta de recursos em informações valiosas, mantendo informações úteis e eliminando informações irrelevantes. Os operadores de *pooling* fornecem uma forma de invariância de transformação espacial, bem como reduzem a complexidade computacional para camadas superiores, eliminando algumas conexões entre camadas convolucionais (SUN et al., 2017).

O *Max-Pooling* é um operador que pode ser aplicado para reduzir a amostragem das saídas convolucionais, reduzindo assim a variabilidade. O operador *max-pooling* transmite o valor máximo dentro de um grupo de R ativações. A m -ésima banda max-pooled é composta por j filtros relacionados da seguinte forma (SUN et al., 2017):

$$P_{j,m} = \max(h_{j,(m-1)N+r}) \quad (3.8)$$

Onde N é um deslocamento que permite a sobreposição entre regiões de agrupamento quando $N < R$. A camada de *pooling* diminui a dimensionalidade de saída de K convolucional para $M = (K - r)/N + 1$ e resultando em uma camada de $p = [p_1, \dots, p_m]$. Um exemplo de operação *max-pooling* pode ser visto na Figura 3.7.

Figura 3.7 – Exemplo de operação de max pooling.




Fonte: (SUN et al., 2017) ADAPTADA.

3.2.6 U-Net

U-net é uma arquitetura de rede neural projetada principalmente para segmentação de imagens (RONNEBERGER; FISCHER; BROX, 2015). A estrutura básica de uma arquitetura U-net consiste em dois caminhos. O primeiro caminho é o caminho de contração, também conhecido como codificador ou caminho de análise, que é semelhante a uma rede de convolução regular e fornece informações de classificação. O segundo é um caminho de expansão, também conhecido como decodificador ou caminho de síntese, que consiste em convoluções ascendentes e concatenações com recursos do caminho de contração. Essa expansão permite que a rede aprenda informações de classificação localizadas. A rede resultante é quase simétrica, dando-lhe uma forma semelhante a um U como pode ser visto na Figura 3.8.

O caminho de contração utiliza uma arquitetura típica da CNN. Cada bloco no caminho de contração consiste em duas convoluções 3×3 sucessivas seguidas por uma função de ativação ReLU e uma camada de *max pooling*. Este arranjo é repetido várias vezes. A novidade do U-net vem na segunda parte, chamada de caminho expansivo, em que cada estágio *up-sampling* do mapa de características usando convolução ascendente 2×2 . Em seguida, o mapa de características da camada correspondente no caminho de contração é concatenado no mapa de características com *up-sampling*. Isto é seguido por duas convoluções 3×3 sucessivas e ativação ReLU. No estágio final, uma convolução 1×1 adicional é aplicada para reduzir o mapa de características ao número necessário de canais e produzir a imagem segmentada. O recorte é necessário porque os pixels nas bordas possuem a menor quantidade de informações contextuais e, portanto, precisam ser descartadas. Isso resulta em uma rede semelhante a um formato de U e, mais importante, propaga informações contextuais ao longo da rede, o que permite segmentar objetos em uma área usando o contexto de uma área sobreposta maior (RONNEBERGER; FISCHER; BROX, 2015).

Figura 3.8 – Arquitetura U-Net.




Fonte: (RONNEBERGER; FISCHER; BROX, 2015).

Além disso, é possível realizar modificações na U-Net de forma a se adaptar melhor ao problema sugerido. Dessa forma, (YOSHIDA et al., 2021) propôs a inserção de camadas de *Batch normalization* entre as camadas de convolução e a ReLU. A arquitetura proposta por (YOSHIDA et al., 2021) pode ser observada na Figura 3.9. Essa modificação apresenta bons resultados em tarefas de segmentação de órgão em imagens médicas, desta forma, obteria um resultado promissor na segmentação de coração em imagens de TC. Neste contexto, esta arquitetura foi utilizada na segmentação do coração, na etapa de extração da região de interesse (ROI) (Seção 4.1).

3.2.7 EfficientNet

A família EfficientNet, proposta por (TAN; LE, 2019), é um conjunto de arquiteturas que surgiram a partir do estudo de um método de escalonamento de modelo que usa uma combinação de coeficientes para alterar a estrutura das redes em diversos aspectos, como número de filtros e de camadas convolucionais. Foram projetadas para serem altamente eficientes em termos de consumo de recursos computacionais enquanto mantêm ou melhoram o desempenho em tarefas de visão computacional. Sua estrutura é composta por blocos denominados MBConv caracterizados por uma combinação entre blocos chamados de *Inverted Bottlenecks* (IB) (SANDLER et al., 2018) e blocos *Squeeze-and-Excitation* (SAE) (HU; SHEN; SUN, 2018). Os blocos IB fazem uso de convoluções em profundidade como uma alternativa à convolução padrão para reduzir custo computacional,


Figura 3.9 – Arquitetura U-Net modificada.



Fonte: (YOSHIDA et al., 2021).

visto que estes possuem menos parâmetros a serem ajustados. Observa-se na Figura 3.10 a arquitetura EfficientNet. Desta forma, uma combinação entre as arquiteturas da U-Net e da EfficientNetB0 e EfficientNetB5 podem alcançar resultados promissores, sendo utilizada na segmentação de calcificações e remoção de falsos positivos (Seções 4.2 e 4.3).

Figura 3.10 – Arquitetura EfficientNet.




Fonte: (WISDOMML, 2023).

4 Método

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 quatro etapas, sendo elas: extração da região de interesse (ROI), segmentação de calcificações, remoção de falsos positivos e classificação da calcificação. Cada etapa é projetada para abordar um aspecto específico da tarefa, conforme ilustrado na Figura 4.1.

Figura 4.1 – Fluxograma do método proposto e suas etapas: (1) extração da ROI, (2) Segmentação das calcificações, (3) Remoção de falsos positivos e (4) Classificação das calcificações.



Fonte: Autoral.

4.1 Extração da ROI


A primeira etapa do método proposto visa a extração de uma região menor, a chamada região de interesse (ROI), que envolva os objetos de interesse da segmentação (calcificações). Dessa forma, pretende-se segmentar o coração nos exames, reduzindo o escopo de cada exame e eliminando regiões de fundo cujas características podem interferir no aprendizado do modelo de segmentação.

4.1.1 Pré-processamento

Com intuito de reduzir processamento e escopo de operações, além de facilitar a utilização de outras técnicas nas imagens, converteu-se as imagens do exame original da escala Hounsfield para 0 a 255 pixels. Essa operação foi realizada através do mapeamento dos valores, e da normalização, dessa forma não se perde os objetos na imagem, e reduz-se os valores de cada pixel.

As variações nos exames de tomografia computadorizada podem ser significativas dependendo do tomógrafo, fabricante, hospital e outros fatores. Portanto, outro pré-processamento aplicado foi a a técnica de *histogram matching* (GONZALEZ, 2009), onde realiza-se a modificação do histograma de uma imagem baseada em um imagem 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 aplicar a técnica de *histogram matching*, utilizou-se como imagem de referência aquela que possuía um maior contraste em seu histograma, de forma a melhorar o contraste em outras imagens. Um exemplo da aplicação do *histogram matching* pode ser visto na Figura 4.2.

Figura 4.2 – Aplicação de *histogram matching*: (a) imagem original (b) imagem de referência e (c) imagem com histograma modificado.



Fonte: Autoral.

Pela Figura 4.2a, percebe-se que apesar de ser detectável, há uma dificuldade em identificar calcificações na imagem, como por exemplo o esterno e a coluna vertebral (indicados pelas setas verde e azul, respectivamente, na Figura 3.3). Ainda mais difícil encontra-se a calcificação na artéria coronária esquerda. Contudo, após aplicar a técnica de *histogram matching*, percebe-se que há um aumento do contraste entre tecidos moles (artérias e coração) e tecidos duros (esterno, costelas e calcificações). Esse contraste auxilia na detecção da área de interesse (coração) e identificação das calcificações nas etapas futuras.

4.1.2 Arquitetura utilizada

Para extração da ROI, é utilizada a arquitetura da U-Net modificada (Seção 3.2.6) proposta por (YOSHIDA et al., 2021) para segmentar o coração de forma a reduzir a imagem e eliminar áreas irrelevantes para o problema como o esterno, costelas, e a coluna vertebral. Esta arquitetura foi utilizada, pois apresenta bons resultados na tarefa de segmentação de órgãos em imagens médicas em comparação à U-Net original, sem elevar muito o custo computacional.

4.1.3 Pós-processamento

Percebe-se na Figura 4.3 que algumas segmentações das fatias do paciente como a fatia (b) nem sempre são completas, e não englobam totalmente a ROI desejada, diferente de outras segmentações como a fatia (a) que possuem uma boa segmentação do coração. Dessa forma, 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 da máscara final, se pelo menos uma segmentação o prever como parte do ROI, ele será marcado como pertencente à ROI. Um exemplo da operação OR aplicada ao problema pode ser visto na Figura 4.3.

Figura 4.3 – Exemplo da operação morfológica OR: (a) fatia a (b) fatia b e (c) máscara final.




Fonte: Autoral.

Assim, através da técnica da operação morfológica OR, garante-se que a máscara final será uma segmentação que englobará a ROI, pois será uma união de todas as segmentações realizadas em cada fatia do paciente.

Com intuito de remover objetos e linhas pequenas que podem estar presentes na máscara final devido à operação OR, é aplicada uma operação de abertura (GONZALEZ, 2009). Com esta técnica, é possível eliminar artefatos presentes na máscara final. Nesta etapa é utilizado um elemento estruturante retangular de tamanho fixo 7×7 . Um exemplo da operação de abertura pode ser visto na Figura 4.4.


Figura 4.4 – Exemplo de operação de abertura: (a) imagem original e (b) imagem resultante.



Fonte: Autoral.

Observando a Figura 4.4, percebe-se que essa técnica remove artefatos encontrados principalmente no contorno da máscara final, enquanto preserva a forma e tamanho de objetos maiores. E por fim, é criado uma *bounding box* em volta da máscara final para garantir que a ROI foi extraída, como pode ser visto na Figura 4.5.

Figura 4.5 – Exemplo de: (a) *bounding box* após pós-processamentos e (b) ROI extraída na primeira etapa.




Fonte: Autoral.

Através da Figura 4.5, nota-se que a extração da ROI cumpriu seu objetivo ao extrair apenas o coração que é onde se encontram as artérias coronárias e portanto onde pode ser encontrado as calcificações alvas, enquanto removeu da imagem algumas áreas que poderiam interferir no processo de segmentação do coração como o esterno e a coluna vertebral.

4.2 Segmentação da calcificação

Na segunda etapa, a segmentação da calcificação, é feita a segmentação inicial das calcificações nas artérias coronárias. Devido ao fato que as imagens de entrada dessa etapa são apenas as ROI extraídas, evita-se possíveis falsos positivos em estruturas como costelas e esterno. A arquitetura utilizada nessa etapa foi a U-Net com o caminho de contração baseado na EfficientNetB0 para extrair características. Este rede foi utilizada devido às vantagens que seus blocos MBConv agregam como: melhora no desempenho em tarefas de visão computacional e eficiência no consumo de recursos operacionais. Na Figura 4.6 pode-se ver a arquitetura de rede utilizada nesta e na etapa de remoção de falsos positivos.


Figura 4.6 – Arquitetura utilizada na segmentação da calcificação.



Fonte: Autoral

Um exemplo da segmentação de calcificação realizada nesta etapa pode ser visto na Figura 4.7.

Figura 4.7 – Exemplo de segmentação de calcificação: (a) fatia de imagem do paciente e (b) predição da rede.



(a)

(b)

Fonte: Autoral.

Como pode ser observado na Figura 4.7, existem 2 calcificações. A indicada pela seta em azul representa uma calcificação na artéria coronária direita, enquanto a indicada pela seta vermelha representa uma calcificação na aorta.


4.3 Remoção de falsos positivos

A etapa de remoção de falsos positivos consiste na remoção de calcificações indesejadas. São utilizadas técnicas e uma arquitetura de rede para remover falsos positivos encontrando em regiões que não são as artérias coronárias e portanto não são calcificações de interesse, como, por exemplo, calcificações na aorta (seta vermelha na Figura 4.7).

4.3.1 Pré-processamento

Durante o pré-processamento dessa etapa, é feito uma *bounding box* em torno de cada predição segmentada na segunda etapa. Esta *bounding box* é expandida, de forma que a imagem contesse um certo nível de informação contextual sobre a localização das calcificações segmentadas, auxiliando no processo de identificar se essa calcificação está ou não presente em uma das artérias coronárias alvo. Além disso, esta expansão não pode ser muito grande de forma a evitar informações irrelevantes na imagem. Esta dimensão deve ser múltipla de 32 para servir de entrada na arquitetura utilizada (a mesma utilizada na etapa de segmentação de calcificação). Portanto a *bounding box* é expandida até o tamanho de 96×96 pixels. Um exemplo desse pré-processamento pode ser observado na Figura 4.8.

Figura 4.8 – Exemplo de pré-processamento da terceira etapa: (a) imagem 512×512 com *bounding box* em vermelho (b) *bounding box* redimensionada para 96×96 e (c) ROI de tamanho 96×96 extraída no pré-processamento.



Fonte: Autoral.


Essas *bounding box* são feitas da seguinte forma: primeiro percorre-se a imagem, e ao encontrar uma predição de calcificação, cria-se uma *bounding box* de 96×96 com essa segmentação ao centro. Após isso, continua-se a percorrer a imagem para identificar se existem outras predições de segmentação fora da *bounding box* já criada. Se houver,

repete-se esse processo. Se não houver, então todas as predições segmentadas já estão englobadas em alguma *bounding box*.

4.3.2 Pós-processamento

O pós-processamento consiste no reposicionamento das imagens 96×96 que foram extraídas no pré-processamento. Essas imagens são reposicionadas na mesma localização da imagem original de onde foram extraídas (imagem 512×512), assim a imagem resultante após a etapa de remoção de falsos positivos é uma imagem 512×512 , as mesmas dimensões da imagem de entrada. Como pode ser observado na Figura 4.9, a imagem 96×96 é realocada na imagem original 512×512 .

Figura 4.9 – Exemplo de: (a) imagem de dimensão 96×96 e (b) imagem de saída da terceira etapa de dimensão 512×512 .



Fonte: Autoral.


4.4 Classificação das calcificações

Na última etapa, a etapa de classificação das calcificações, as calcificações segmentadas anteriormente serão classificadas em 3 classes, sendo elas: Artéria Coronária direita (RCA), Artéria Descendente Esquerda (LAD) e Artéria Circunflexa Esquerda (LCX). Estas classificações serão dadas de acordo com o posicionamento da calcificação no coração, como pode ser visto na Figura 4.10.

De acordo com a Figura 4.10, percebe-se que a classe LCX representa as calcificações encontradas na artéria descendente circunflexa, já a classe RCA representa as calcificações localizadas na artéria coronária direita, e por fim LAD representa as calcificações encontradas na artéria coronária esquerda.

Como a classificação é feita baseada na localização, portanto utilizou-se dessa característica para classificar automaticamente as segmentações da etapa anterior. Dessa forma, primeiramente utilizando a fatia correspondente daquela em que foi segmentada a


Figura 4.10 – Exemplos de classificação da classe: (a) LAD (b) LAD e LCX e (c) RCA.



Fonte: (WOLTERINK et al., 2016).

calcificação, toma-se a segmentação do coração realizada na etapa de extração da ROI (Seção 4.1). Assim, possui-se a segmentação da calcificação e do coração da mesma fatia e portanto podemos determinar sua localização através da divisão de quadrantes do coração. A segmentação do coração é dividido em 4 quadrantes iguais, e cada quadrante representará uma classificação da calcificação. A divisão de quadrantes do coração pode ser vista na Figura 4.11.


Figura 4.11 – Divisão dos quadrantes do coração por classe: 1º Quadrante é da classe LAD, 2º quadrante é da classe RCA, 3º quadrante é da classe fundo e 4º quadrante é da classe LCX.



Fonte: Autoral.

A fim de auxiliar no entendimento, será demonstrado um exemplo. Suponha-se que segmentou-se uma calcificação na fatia N de um paciente P. Então através da primeira etapa do método, obtém-se a segmentação do coração nessa fatia, e a partir dela, dividi-se o coração em quadrantes. E por fim, verifica-se em qual quadrante se encontra a segmentação da calcificação para determinar sua classe e seu volume através do escore de Agatston como foi descrito na Seção 3.1. Esse processo pode ser visto na Figura 4.12.

Figura 4.12 – Exemplos do processo para classificação de calcificação: (a) Fatia N do paciente P (b) segmentação do coração da fatia N (c) divisão do coração em quadrantes (d) quadrantes na fatia N e (e) posição de cada calcificação nos quadrantes



Fonte: Autoral.

Obersevando a Figura 4.12, percebe-se que esse paciente possui calcificação nos quadrantes 1 e 4, portanto das classes LAD e LCX, respectivamente. Então os volumes dessas calcificações são calculados para avaliar o grau de severidade do paciente a partir do escore de Agatston.

4.5 Métricas de avaliação

Para avaliar quão bem o método realiza a segmentação e classificação existem diversas métricas que podem ser utilizadas. Para cada imagem de entrada o modelo prediz uma classe para cada pixel. Isso é então comparado com *ground-truth*, que é uma image do mesmo tamanho que a imagem de entrada onde cada pixel tem o rótulo de sua classe verdadeira. Existem quatro resultados possíveis para cada pixel ao comparar a classe prevista com o *ground-truth* dessa classe (KJERLAND, 2017):

- Verdadeiro Positivo (VP): Quando o modelo prediz que o pixel é da classe i , e a classe do pixel é i no *ground-truth*;

- Verdadeiro negativo (VN): Quando o modelo prediz que o pixel não é da classe i , e a classe do pixel não é i no *ground-truth*;
- Falso Positivo (FP): Quando o modelo prediz que o pixel é da classe i , e a classe do pixel não é i no *ground-truth*; e
- Falso Negativo (FN): Quando o modelo prediz o pixel não é da classe i , e a classe do pixel é i no *ground-truth*.

Existem métricas para avaliar tarefas de segmentação e de classificação. Para avaliar a tarefa de segmentação utilizou-se a precisão, sensibilidade e F1-Score. Enquanto para avaliar a tarefa de classificação utilizou-se o Coeficiente de Correlação Intraclass (ICC) e o Kappa.

A precisão indica que dentre todas as classificações de classe positivo que o modelo fez, quantas estão corretas. Essa métrica avalia os falsos positivos como mais prejudiciais que os falsos negativos, ou seja, a métrica diminui a medida que se tem mais falsos positivos. Essa métrica pode ser descrita pela Equação 4.1 (RODRIGUES, 2019).

$$P = \frac{VP}{VP + FP} \quad (4.1)$$

A sensibilidade indica que dentre todas as situações de classe positivo como valor esperado, quantas estão corretas. Essa métrica avalia os falsos negativos como mais prejudiciais que os falsos positivos, ou seja, o valor da métrica diminui de acordo com o número de falsos negativos e ela pode ser descrita pela Equação 4.2 (RODRIGUES, 2019).

$$S = \frac{VP}{VP + FN} \quad (4.2)$$

O F1-score é a média harmônica entre precisão e sensibilidade, ou seja, é uma maneira de observar somente 1 métrica ao invés de duas (precisão e sensibilidade) em alguma situação. Quando tem-se um F1-Score baixo, é um indicativo de que ou a precisão ou a sensibilidade está baixo. Essa métrica pode ser descrita pela Equação 4.3 (RODRIGUES, 2019).

$$F1 = 2 \times \frac{Precisão \times Sensibilidade}{Precisão + Sensibilidade} \quad (4.3)$$

O coeficiente de correlação intraclass é calculado por meio de quadrados médios (ou seja, estimativas das variâncias populacionais baseadas na variabilidade entre um determinado conjunto de medidas) obtidos através da análise de variância. Atualmente, o ICC tem sido amplamente utilizado na medicina para avaliar a confiabilidade entre avaliadores, testes e intra-avaliadores. Essas avaliações são fundamentais à avaliação clínica

porque, sem eles, não se possui confiança nas medições, nem pode-se tirar quaisquer conclusões racionais delas (KOO; LI, 2016). Existem diferentes formas de ICC que podem dar resultados diferentes quando aplicadas ao mesmo conjunto de dados, e as formas de relatar o ICC podem variar entre os pesquisadores. Dessa forma, adotou-se o *two-way intraclass correlation coefficient (ICC) for absolute agreement* que é calculado conforme a Equação 4.4 (KOO; LI, 2016):

$$ICC = \frac{MSWM - MSE}{MSWM - MSE + MSWS} \quad (4.4)$$

Onde *MSWM* (*Mean Square Within Measurements*) representa o quadrado médio entre as medidas de um mesmo grupo, *MSE* (*Mean Square Error*) é o erro quadrado médio e *MSWS* (*Mean Square Within Subjects*) representa o quadrado médio entre os grupos. Dessa forma, analisa-se se as medidas de cada grupo se assemelham entre si e se os grupos se diferem entre si (KOO; LI, 2016).

Para o grau de severidade de cada paciente, será usado o Kappa ponderado. O Kappa ponderado é usado quando se tem o objetivo de ponderar mais os erros próximos (por exemplo, 1-2) do que os erros mais distantes (por exemplo, 1-3). Uma escala ordinal onde uma diferença de 1 ponto pode ser considerada menos incorreta do que uma diferença de 2 pontos. O kappa ponderado é descrito pela Equação 4.5 (WARRENS, 2012):

$$K_w = \frac{P_o - P_e}{1 - P_e} \quad (4.5)$$

Onde P_o é a proporção de concordância observada, ou seja, é a proporção de casos para os quais os dois avaliadores (especialista e modelo) concordam, enquanto P_e é a proporção de chance de concordância, ou seja, é a proporção de casos para os quais os avaliadores concordariam se simplesmente predisssem números aleatórios, por exemplo, P_e seria de 0.5 se um modelo tivesse que adivinhar um número entre 1 e 2.

5 Resultados e Discussão

Neste capítulo são apresentados e discutidos os resultados obtidos nos experimentos realizados para a validação da metodologia proposta. Além dos resultados numéricos, são apresentados resultados visuais, que permitem observar as semelhanças entre as marcações do especialista e as realizadas pelo modelo. Também são apresentadas as bases de imagens utilizadas em cada uma das etapas, tanto para treinamento quanto para teste. Os resultados apresentados foram obtidos de acordo com experimentos comparando diversas arquiteturas e modelos com e sem os processamentos propostos.

5.1 Base de imagens

Para realizar os experimentos projetados foram utilizados 3 bases de imagens diferentes. A primeira base CT Heart Dataset ([TOMAR, 2022](#)) é utilizada na etapa de extração da ROI, pois essa possui a marcação do coração. A segunda base é a OrCaScore Dataset ([WOLTERINK et al., 2016](#)), que é utilizada na etapa de segmentação de calcificações, e esta possui marcação das calcificações. E por último é utilizada uma base de imagens própria produzida para treino da etapa de remoção de falsos positivos do método.

5.1.1 Base de imagens CT Heart

Essa base de imagens consiste em exames de tomografia computadorizada de 20 pacientes, totalizando 2532 fatias de imagens, com marcação do coração, feito por um especialista, em cada um dos exames. Esse conjunto de dados foi dividido em 60% para treinamento, 20% para validação e 20% para teste. Três técnicas de aumento de dados foram aplicadas durante o treinamento, incluindo *flip* horizontal, *flip* vertical e rotação de 45°. Por fim a distribuição ficou de 6076 imagens para treinamento, 506 imagens para validação e 506 imagens para teste.

5.1.2 Base de imagens OrCaScore

Essa base de imagens consiste em exames de 32 pacientes feitos em 4 tomógrafos diferentes de 4 hospitais diferentes, dessa forma possuindo uma grande diversidade de exames, totalizando 1540 fatias de imagens. Possui a marcação das calcificações nas artérias coronárias feita por 2 especialistas. O conjunto foi dividido em 20 pacientes para treino, 4 pacientes para validação e 8 pacientes para teste. Técnicas de aumento de dados foram aplicadas no conjunto de treino, sendo elas *flip* horizontal, *flip* vertical, *zoom in* e rotação

de 45°. Após isso, o conjunto de treino consistiu em 4248 imagens, o de validação em 150 imagens e o de teste em 301 imagens.

5.1.3 Base de imagens própria

A terceira base de imagens foi formada a partir do pré-processamento da terceira etapa, que consistiu na extração de ROIs de 96×96 das predições da segunda etapa, bem como ROIs das máscaras do segundo conjunto de dados (OrCaScore). Dessa forma, esse conjunto possui 198 imagens verdadeiras positivas e 32 falsas positivas. Foram aplicadas técnicas de aumento de dados de formas distintas. Nas imagens verdadeiras positivas foram aplicadas apenas 3 técnicas de aumento de dados, totalizando 540 imagens, enquanto nas imagens falsas positivas foram aplicadas 10 técnicas de aumento de dados sendo elas *flip* vertical, *flip* horizontal e rotação de 10° a 70° com incremento de 5°, totalizando 240 imagens.

5.2 Configuração dos experimentos

Todos os experimentos foram realizados em um *hardware* com as seguintes especificações: CPU Intel Core i7-9700KF, 8 GB de memória RAM, placa gráfica NVIDIA GTX 1660 Super com 6 GB de VRAM e sistema operacional Windows 10.

Para a etapa de extração da ROI foi utilizada a base de imagens CT Heart Dataset, foi treinada durante 70 épocas, com um *batch size* de tamanho 2, uma taxa de aprendizado de 1e-4, *early stopping* com 5 épocas de paciência, Dice Loss como função de perda devido aos bons resultados em segmentação de órgãos, e a arquitetura proposta por (YOSHIDA et al., 2021).

Na etapa de segmentação de calcificação utilizou-se a base de imagens OrCaScore Dataset, foi treinada durante 100 épocas, com um *batch size* de tamanho 4, uma taxa de aprendizado de 1e-4, *early stopping* com 7 épocas de paciência, Focal Loss como função de perda por melhorar o desempenho em base de imagens que possuem desbalanceamento entre classes como a OrCaScore, e a arquitetura descrita na Seção 4.2.

Para a etapa de remoção de falsos positivos, utilizou-se a base de imagens própria, treinada durante 50 épocas, com um *batch size* de tamanho 24, uma taxa de aprendizado de 1e-4, *early stopping* com 5 épocas de paciência, Focal Loss como função de perda pelos mesmos motivos da etapa anterior, e a arquitetura descrita na Seção 4.2.

5.3 Experimentos

Os experimentos realizados serão comparados através das métricas escolhidas e a partir da visualização das imagens, e estão divididos para cada etapa do método, onde as três primeiras etapas são referentes à tarefa de segmentação das calcificações e a quarta etapa é referente à classificação das calcificações. Vale lembrar que todas as comparações foram feitas tendo a mesma divisão de treino e teste, garantindo uma comparação justa.

5.3.1 Extração da ROI

O primeiro teste realizado corresponde à comparação entre a U-Net original e a U-Net modificada na tarefa de extração da ROI. Esta comparação é realizada de forma a validar o uso da modificação proposta por (YOSHIDA et al., 2021) na tarefa de segmentação de órgão em imagens médicas. Esta comparação pode ser vista na Tabela 5.1. É importante ressaltar que essas métricas foram obtidas testando apenas no conjunto de dados TC Heart, pois este possui as marcações do especialista para o coração. E também este teste foi realizado sem nenhum tipo de pré-processamento.

Tabela 5.1 – Comparação de arquiteturas para extração da ROI

Arquitetura	F1-Score (%)	Precisão (%)	Sensibilidade (%)
U-Net	63,0	93,3	63,2
U-Net de (YOSHIDA et al., 2021)	85,0	96,8	85,4


Fonte: Autoral.

Como pode ser observado na Tabela 5.1, a arquitetura da U-Net de (YOSHIDA et al., 2021) apresentou melhores resultados na tarefa de segmentação de coração, e portanto foi utilizada para extrair a ROI do conjunto de dados OrCaScore. Alguns exemplos de ROI extraídas do conjunto OrCaScore utilizando a U-Net modificada pode ser visto na Figura 5.1.

Além disso, como o método pra extração da ROI é bem similar ao realizado pela YOLO, então realizou-se a comparação da extração da ROI pelo método proposto e da YOLOv8 (ULTRALYTICS, 2023). Essa comparação foi feita de duas formas: avaliando o quão bem é feita a extração da ROI, e o quanto essa extração auxilia na tarefa de segmentação da calcificação. Na Tabela 5.2 pode-se ver a comparação entre as métricas dos dois modelos.

O modelo da YOLOv8 possui melhores métricas e portanto realizou a tarefa de extração da ROI mais apropriadamente como pode ser vista na Figura 5.2. As ROIs extraídas utilizando a YOLO são menores e portanto contém menos estruturas ósseas como o esterno, costelas e coluna vertebral. Contudo, quando os métodos de extração

Figura 5.1 – Exemplos de extração da ROI na base OrCaScore: (a) Fatia original paciente 1 (b) Fatia original paciente 2 (c) Fatia original paciente 3 (d) ROI extraída do paciente 1 (e) ROI extraída do paciente 2 e (f) ROI extraída do paciente 3



Fonte: Autoral.

Tabela 5.2 – Comparação de modelos para extração da ROI

Modelo	F1-Score (%)	Precisão (%)	Sensibilidade (%)
Extração da ROI proposta	86,7	87,1	88,3
YOLOv8	97,9	98,7	98,4


Fonte: Autoral.

de ROI são comparados para a tarefa de segmentação de calcificação, percebe-se que as ROIs extraídas pelo método proposto apresentam melhores resultados como será mostrado posteriormente.

5.3.2 Segmentação da calcificação

Nesta etapa, testes foram realizados com imagens sem e com o *histogram matching* com intuito de validar a melhora nas métricas quando diferentes tipos de imagens são mais similares umas às outras, bem como aumentar o contraste entre calcificações e tecidos. Este teste foi realizado utilizando tanto as ROIs extraídas pelo método proposto de extração quanto pela YOLOv8. A comparação entre estes testes pode ser visualizada na Tabela 5.3. Neste teste foi realizado a validação cruzada com 3 *folds* para de fato determinar que a melhora ocorreu devido ao *histogram matching*. A métricas estão sendo demonstradas da

Figura 5.2 – Exemplos de ROI extraídas : (a) paciente 1 (método proposto) (b) paciente 2 (método proposto) (c) paciente 3 (método proposto) (d) paciente 1 (YOLOv8) (e) paciente 2 (YOLOv8) e (f) paciente 3 (YOLOv8)



Fonte: Autoral.

Tabela 5.3 – Comparação entre imagens com e sem *histogram matching* com as ROIs extraídas pelos dois métodos

Imagem	F1-Score (%)	Precisão (%)	Sensibilidade (%)
Sem <i>histogram matching</i> Método proposto	14,3 $\pm$ 1,3	13,3 $\pm$ 2,1	14,1 $\pm$ 0,7
Com <i>histogram matching</i> Método proposto	83,1 $\pm$ 1,4	93,0 $\pm$ 1,0	85,2 $\pm$ 0,4
Sem <i>histogram matching</i> YOLOv8	16,2 $\pm$ 0,5	17,1 $\pm$ 1,1	15,5 $\pm$ 0,7
Com <i>histogram matching</i> YOLOv8	81,2 $\pm$ 1,0	91,5 $\pm$ 1,0	83,1 $\pm$ 0,2

Fonte: Autoral.

seguinte forma: média $\pm$ desvio padrão.

Pelas métricas vistas na Tabela 5.3, percebe-se que o uso da técnica de *histogram matching* auxilia o modelo na identificação de calcificação, principalmente por tornar os diversos exames de tomógrafos diferentes mais semelhantes entre si, e por aumentar o contraste entre os tecidos e as calcificações.

Em seguida, validou-se a utilização da etapa de extração da ROI ao comparar a

tarefa de segmentação da calcificação com e sem a ROI extraída, bem como o uso da função de perda escolhida. Comparou-se a função de perda Dice Loss que é uma função de perda mais conhecida com a função Focal Loss que possui mecanismos para problemas com classes desbalanceadas como o caso abordado nesse trabalho. Essa comparação pode ser vista na Tabela 5.4.

Tabela 5.4 – Comparação entre modelos e funções de perdas

Modelo	F1-Score	Precisão	Sensibilidade
Sem extração da ROI e Dice	72,9	73,7	95,9
Sem extração da ROI e Focal	94,3	98,2	94,9
Com extração da ROI e Dice (Método Proposto)	81,7	84,2	95,0
Com extração da ROI e Focal (Método proposto)	95,0	97,1	96,7
Com extração da ROI e Dice (YOLOv8)	80,2	85,3	93,1
Com extração da ROI e Focal (YOLOv8)	94,2	98,0	94,7

Fonte: Autoral.

Observando a tabela, percebe-se que a utilização da Focal Loss e a etapa de extração da ROI auxiliam na tarefa de segmentação da calcificação. Dessa forma, vale comparar qual das ROIs extraídas (método proposto, YOLOv8) apresentam melhores resultados na tarefa de segmentação. Essa comparação pode ser vista na Tabela 5.5.

Tabela 5.5 – Comparação de segmentação da calcificação utilizando ROI extraída pelos dois modelos

Modelo de extração da ROI	F1-Score (%)	Precisão (%)	Sensibilidade (%)
Extração da ROI proposta	96,6	98,0	97,2
YOLOv8	95,8	98,9	95,4

Fonte: Autoral.

Pela Tabela 5.5, percebe-se que a única métrica da YOLOv8 que é melhor é a precisão. Isso se deve ao fato que como esse modelo realiza menos previsões, portanto, possui menos falsos positivos, aumentando essa métrica. Entretanto, opta-se pelo método proposto, por esse apresentar uma sensibilidade maior, e assim evita-se mais falsos negativos. No âmbito atual, é ideal que se possua menos falsos negativos, pois assim evita-se que um paciente com calcificação seja diagnosticado como saudável. Além de que o método proposto também possui um F1-Score maior, que é uma média harmônica entre sensibilidade e precisão. O método proposto apresenta resultados mais significantes devido ao fato que as ROIs possuem mais informações contextuais se comparadas as extraídas pela YOLOv8.

Para avaliar arquiteturas com mais parâmetros, mais profundas e que utilizam outras técnicas, foi feita a comparação da arquitetura utilizada na etapa de segmentação de calcificação com outras arquiteturas, especificamente a U-Net com outras modificações no caminho de contração como ResNet-50 e EfficientNetB3, bem como arquiteturas que utilizam convoluções dilatadas como a DeepLab. Observa-se na Tabela 5.6 as métricas obtidas por cada arquitetura na tarefa de segmentação da calcificação.

Tabela 5.6 – Comparação entre arquiteturas na segmentação de calcificação

Arquitetura	F1-Score	Precisão	Sensibilidade
U-Net	81,7	95,0	84,2
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
DeepLabv3	84,3	92,1	88,4
DeepLabv3 + ResNet-50	93,4	98,0	93,8
DeepLabv3 + EfficientNetB3	91,7	97,1	93,3

Fonte: Autoral.

A U-Net modificada com EfficientNetB0 foi escolhida, pois é a que possui maior F1-Score, portanto possui a maior média harmônica entre sensibilidade e precisão. Isso demonstra que os blocos MBConv de fato auxiliam na tarefa de segmentação no âmbito de visão computacional. Após confirmar a efetividade da arquitetura na tarefa de segmentação de calcificação na artéria coronária, o método foi validado utilizando a validação cruzada. Observa-se na Tabela 5.7 as métricas, média e desvio padrão para cada *fold* de validação. Como a divisão de treino/teste é de 75%/25%, então a validação cruzada foi realizada com 4 *folds*.

Tabela 5.7 – Resultados da validação cruzada

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

Fonte: Autoral.


Pela Tabela 5.7, percebe-se que o modelo possui boas métricas na tarefa de segmentação da calcificação independente do conjunto treino e teste. Isso pode ser visto através

da média que possui valores acima dos 90% e também do desvio padrão que possui valores abaixo de 3%, mostrando a consistência e efetividade do método.

5.3.3 Remoção de falsos positivos

O modelo analisado até a etapa anterior possui alguns falsos positivos, principalmente na área central do coração, onde possui calcificações na aorta, como pode ser visto pela seta vermelha na Figura 5.3. Essas calcificações não estão presentes nas artérias coronárias, portanto mesmo que sejam calcificações, são falsos positivos que devem ser evitados. Nesse contexto, esta etapa se faz necessária.

Figura 5.3 – Exemplo de segmentação de calcificação: (a) imagem original (b) *ground-truth* e (c) predição



Fonte: Autoral.

Dessa forma, pode-se ver uma comparação entre o modelo com e sem a terceira etapa na Tabela 5.8. O intuito é eliminar apenas as segmentações falso positivas, e manter apenas as segmentações verdadeiras positivas.

Tabela 5.8 – Comparação do método com e sem a etapa de remoção de falsos positivos


Modelo	F1-Score (%)	Precisão (%)	Sensibilidade (%)
Sem remoção de falsos positivos	96,6	98,0	97,2
Com remoção de falsos positivos	96,8	98,3	97,0

Fonte: Autoral.

Pela Tabela 5.8, percebe-se apenas um pequeno aumento nas métricas de F1-Score e precisão, e isso se deve ao fato que apesar de remover falsos positivos do modelo, a classe de fundo é bem maior que a classe calcificação, dessa forma, ao remover alguns falsos positivos, o aumento nas métricas é pequeno. Pode-se observar também uma diminuição na métrica da sensibilidade, e isso está relacionado as pequenas diminuições nas segmentações que já estavam presentes no modelo, ou seja, as segmentações verdadeiras positivas, tiveram uma

pequena perda de pixels nas bordas. Entretanto, isso não afeta significamente o método devido ao fato que as calcificações continuam sendo identificadas e segmentadas. Um exemplo de imagem após a etapa de remoção de falso positivo pode ser vista na Figura 5.4.

Figura 5.4 – Exemplo de segmentação de calcificação: (a) imagem original (b) *ground-truth* e (c) predição



Fonte: Autoral.

Nessa figura, a presença da calcificação na aorta, indicada pela seta em vermelha, não é segmentada pelo método, demonstrando a efetividade da etapa de remoção de falsos positivos. Em seguida, realizou-se a análise de outras arquiteturas para essa etapa, assim como foi realizada na etapa anterior, de forma a determinar qual arquitetura teria melhor desempenho nessa tarefa. A comparação dessas arquiteturas na etapa de remoção de falsos positivos pode ser vista na Figura 5.9.

Tabela 5.9 – Comparação entre arquiteturas na remoção de falsos positivos

Arquitetura	F1-Score (%)	Precisão (%)	Sensibilidade (%)
U-Net + Resnet-34	95,9	97,5	96,8
U-Net + Resnet-50	95,8	97,2	96,4
U-Net + Resnet-101	96,1	97,6	97,1
U-Net + EfficientNetB0	96,8	98,2	97,0
U-Net + EfficientNetB3	96,2	97,3	97,0
U-Net + EfficientNetB5	96,9	98,3	97,2


Fonte: Autoral.

Observando a Tabela 5.9, percebe-se que a U-Net com EfficientNetB5 apresenta uma melhora nas métricas em relação à EfficientNetB0 na tarefa de remoção de falsos positivos. Apesar da melhora não ser muito perceptível pelas métricas, ela se dá na segmentação dos pixels das bordas das calcificações verdadeiras positivas, tornando o método ainda mais preciso.

5.3.4 Classificação das calcificações

Nesta etapa foram realizados testes de forma a identificar a melhor forma de classificação. Foi realizado um teste para comparar se as calcificações seriam melhor classificadas se a divisão de quadrantes fosse feita a partir da *bounding box* da máscara final ou da segmentação do coração da fatia correspondente. A comparação entre as duas formas de divisão de quadrante pode ser vista na Figura 5.5.

Figura 5.5 – Exemplo de divisão dos quadrantes do coração: (a) Baseada na *bounding box* da máscara final e (b) baseada na segmentação do coração da fatia correspondente



Fonte: Autoral.

Pela Figura 5.5, pode-se concluir que utilizando a segmentação do coração da fatia correspondente, a divisão do coração é feita de forma mais precisa dos quadrantes. Para validar isso, comparou-se a matriz de confusão de ambos os métodos baseado nas classificações de cada calcificação, como pode ser observado na Figura 5.6.

Figura 5.6 – Comparação das matrizes de confusão: (a) Baseada na *bounding box* da máscara final e (b) baseada na segmentação do coração da fatia correspondente

		GROUND-TRUTH					GROUND-TRUTH		
PREDIÇÃO		LAD	LCX	RCA	PREDIÇÃO		LAD	LCX	RCA
	LAD	16	3	0		LAD	20	0	0
	LCX	7	12	0		LCX	4	15	0
	RCA	1	0	16		RCA	0	0	16

(a)
(b)

Fonte: Autoral.

Pela comparação das matrizes de confusão, nota-se que utilizando a segmentação do coração na fatia correspondente possui melhores classificações, e isso se deve ao fato que a divisão dos quadrantes é mais precisa e portanto separa mais satisfatoriamente cada artéria coronária.

Determinado o método de divisão dos quadrantes, realizou-se o cálculo do escore de Agatston dos pacientes para determinar seus graus de severidade. Lembrando que esse escore é baseado no volume das calcificações de todas as fatias. A matriz de confusão do escore de Agatston pode ser vista na Figura 5.7.

Figura 5.7 – Matriz de confusão do escore de Agatston

		GROUND-TRUTH			
PREDIÇÃO		0	1-100	101-400	>401
	0	3	0	0	0
	1-100	0	0	0	0
	101-300	0	0	3	0
	>300	0	0	0	2

Fonte: Autoral.

Observando a Figura 5.7, percebe-se que o método classifica todos os pacientes nos seus respectivos graus de severidade, seguindo o escore de Agatston. Em seguida, verifica-se a métrica de ICC dos pacientes em relação a cada artéria coronária (LAD, LCX e RCA) e também para o volume total (somando todas as artérias coronárias). Essa métrica pode ser vista Tabela 5.10.

Tabela 5.10 – Métrica ICC para cada artéria e todas as artérias

Todas as classes	RCA (%)	LAD (%)	LCX (%)
99,0	95,9	95,8	97,3

Fonte: Autoral.

Pela Tabela 5.10, nota-se uma grande precisão em todas as classes. Entretanto, quando é feito o cálculo de ICC para todas as classes se obtém uma métrica melhor quando comparada em cada classe separadamente. Isso se deve ao fato que o volume total de calcificação do paciente previsto está bem próximo do real, contudo quando classificadas as calcificações, alguns erros como classificar calcificação LAD como LCX, tornou o volume dessas 2 classes mais distantes do real e portanto diminuindo a métrica. Ainda sim, os valores são bem satisfatórios por estarem acima de 95%.

Por fim, é feito o cálculo da métrica Kappa ponderado que é realizado baseado no escore de Agatston do paciente. Essa métrica é 1, pois como todos os escores do pacientes são previstos corretamente, não possui diferença entre o valor previsto e o valor real.

5.4 Comparação com trabalhos relacionados

Na tarefa de segmentação da classificação da artéria coronária, o método proposto apresenta resultados positivos próximos aos trabalhos anteriores, como pode ser visto na Tabela 5.11

Tabela 5.11 – Comparação entre métodos de segmentação da calcificação na artéria coronária

Método	F1-Score (%)	Precisão (%)	Sensibilidade (%)
(ZHENG; TEK; FUNKA-LEA, 2013)	89,3	93,7	85,3
(DING et al., 2015)	94,3	93,8	94,9
(VOS et al., 2019)	91,0	87,0	95,0
(ZHANG et al., 2019)	92,8	98,4	96,1
(MARTIN et al., 2020)	94,7	95,8	93,5
(OEVER et al., 2020)	94,1	88,9	100,0
(GOGIN et al., 2021)	97,5	99,5	96,8
(LEE et al., 2021)	96,2	97,3	97,0
(FÖLLMER et al., 2022)	95,4	99,1	91,1
(IHDAYHID et al., 2023)	96,6	-	-
Método proposto	96,9	98,3	97,2

Fonte: Autoral.

O método proposto possui métricas próximas às de (GOGIN et al., 2021). Seu método utiliza 5 3D U-Nets para segmentação, o que requer alto custo computacional e configuração poderosa de *hardware*, bem como uma arquitetura bem mais complexa que a arquitetura do método proposto. Baseado nisso, o método proposto supera sua métrica de sensibilidade, sendo que esta métrica avalia os falsos negativos, e portanto o método proposto evita que pacientes doentes sejam classificados como saudáveis, ainda que as configurações de *hardware* sejam diferentes. Isto se deve ao fato do uso dos blocos da MBConv que auxiliam na eficiência do processo de segmentação sem necessitar de alto custo computacional. Além disso, o método também supera métodos que utilizam CNNs 3D como o de (IHDAYHID et al., 2023). Ressalta-se que o método proposto usa menos recurso de *hardware* e ainda sim apresentam resultados próximos ou superiores aos de métodos mais robustos. Também é realizada a comparação com trabalhos que não utilizam aprendizado profundo como (DING et al., 2015) e (ZHENG; TEK; FUNKA-LEA, 2013), mostrando assim a eficiência de utilizar aprendizado profundo em oposição ao aprendizado de máquina clássico para o problema abordado.

Enquanto na tarefa de classificação, o método proposto também apresenta resultados promissores quando comparados aos trabalhos anteriores, como pode ser observado na Tabela 5.12.

Tabela 5.12 – Comparação entre métodos de classificação da calcificação na artéria coronária utilizando métrica ICC

Método	Todas as classes (%)	LAD (%)	LCX (%)	RCA (%)
(DING et al., 2015)	98,0	94,0	87,0	96,0
(IHDAYHID et al., 2023)	99,0	-	-	-
(VOS et al., 2019)	99,0	-	-	-
(ZHANG et al., 2019)	98,0	96,8	97,0	97,8
(MARTIN et al., 2020)	97,4	97,1	96,0	93,0
(OEVER et al., 2020)	98,0	-	-	-
(GOGIN et al., 2021)	99,5	-	-	-
(LEE et al., 2021)	98,0	97,0	95,5	96,4
(FÖLLMER et al., 2022)	98,5	-	-	-
Método proposto	99,0	95,9	95,8	97,3

Fonte: Autoral.

Percebe-se, pela Tabela 5.12, que o método proposto possui uma ótima segmentação, pois ao calcular o volume completo, a predição se aproxima muito do valor real, se aproximando de trabalhos como (GOGIN et al., 2021). Além disso, nota-se que em relação às calcificações em cada artéria, o método proposto possui certas limitações em relação as classes LAD e LCX, principalmente por essas duas classes serem muito próximas uma da outra na localização do coração, enquanto a classe RCA se aproxima bastante de trabalhos anteriores como o de (ZHANG et al., 2019).

6 Conclusão

A segmentação e classificação de calcificação na artéria coronária é uma tarefa que requer muito tempo e esforço do profissional na sua execução. Métodos de segmentação e classificação automáticas de calcificação na artéria coronária tem sido desenvolvidas de forma a auxiliar o profissional da saúde no diagnóstico mais preciso e rápido do paciente.

Este trabalho propõe um método de segmentação e classificação automática de calcificação na artéria coronária em imagens de tomografia computadorizada utilizando aprendizado profundo. Para tal objetivo, dividiu-se em quatro etapas, onde cada etapa é responsável por uma tarefa no método. Além disso, utiliza-se um pré-processamento que não foi utilizado em trabalhos anteriores que auxiliaram no problema proposto. Utiliza, ainda, 2 arquiteturas diferentes para o objetivo final da tarefa, sendo uma delas a U-Net com blocos de *batch-normalization* após camadas de convolução, e U-Net com o caminho de contração modificado pela EfficientNetB0 e pela EfficientNetB5. O método possui 4 etapas, sendo elas: extração da ROI, segmentação da calcificação, remoção de falsos positivos e por fim classificação da calcificação. O método proposto combina todas essas etapas e técnicas para atingir uma melhor qualidade no problema abordado.

Os resultados indicam que o método proposto consegue segmentar e classificar calcificações nas artérias coronárias de forma automática. Nos experimentos realizados, técnicas como *histogram matching* contribuíram significativamente no problema, apesar de trabalhos anteriores não abordarem-na. Outras contribuições observadas foi a utilização de um conjunto de técnicas e arquitetura específica para extração de ROI em vez de uma arquitetura conhecida como YOLOv8, pois quando comparadas, percebeu-se que utilizar uma etapa como um todo, trouxe melhores resultados. Notou-se também que extrair a ROI, em vez de passar direto para a segmentação auxiliou na melhora das métricas. Uma etapa específica com suas respectivas técnicas e arquitetura para remoção de falsos positivos tornou o método mais confiável ao garantir que segmentações errôneas fossem eliminadas do processo. Uma forma de classificação baseada na localização das calcificações, sem utilizar aprendizado profundo, também auxiliou na redução do custo computacional do método, sem trazer consigo grandes revés. Desta forma, um método com custo computacional menor que os utilizados em trabalhos anteriores e que apresenta resultados equiparáveis foi desenvolvido.

Considerando os resultados dos experimentos e a comparação com outros trabalhos, pode-se afirmar que o método consegue realizar a tarefa de formar satisfatória. Compreende-se ainda que os resultados levantam indícios que o método proposto pode de fato auxiliar o profissional da saúde na tarefa de segmentação e classificação de calcificação na artéria

coronária. Portanto, se entende que os objetivos deste trabalho foram atingidos.

Como trabalhos futuros, sugere-se a análise do tempo necessário que um exame completo de tomografia computadorizada seja diagnosticado pelo método proposto. Ainda nesse contexto, pode-se avaliar e remover filtros das arquiteturas utilizadas de forma a acelerar esse processo de diagnóstico, para que o paciente tenha uma resposta mais rápida. Outra sugestão é a utilização de outros tipos de arquiteturas mais recentes como Transformers e ConvNext que podem conter técnicas e filtros que auxiliariam na identificação de características que as arquiteturas utilizadas não detectaram.

Referências

- ACHARYA, U. R. et al. Linear and nonlinear analysis of normal and cad-affected heart rate signals. *Computer methods and programs in biomedicine*, Elsevier, v. 113, n. 1, p. 55–68, 2014. Citado na página 15.
- AGATSTON, A. S. et al. Quantification of coronary artery calcium using ultrafast computed tomography. *Journal of the American college of cardiology*, Elsevier, v. 15, n. 4, p. 827–832, 1990. Citado na página 24.
- APICELLA, A. et al. A survey on modern trainable activation functions. *Neural Networks*, Elsevier, v. 138, p. 14–32, 2021. Citado na página 27.
- BARSNESS, G. W.; HOLMES, D. R. *Coronary Artery Disease: New Approaches Without Traditional Revascularization*. [S.l.]: Springer Science & Business Media, 2011. Citado na página 23.
- BICHARA, J. L. et al. Socioeconomic indicators and mortality from ischemic heart disease and cerebrovascular disease in brazil from 2000 to 2019. *Arquivos Brasileiros de Cardiologia*, SciELO Brasil, v. 120, p. e20220832, 2023. Citado na página 14.
- BLAHA, M. J. et al. Coronary artery calcium scoring: is it time for a change in methodology? *JACC: Cardiovascular Imaging*, American College of Cardiology Foundation Washington, DC, v. 10, n. 8, p. 923–937, 2017. Citado na página 14.
- CHAKLADAR, A. et al. *Angiografia Arterial Coronária*. 2017. Disponível em: <<https://resources.wfsahq.org/atotw/2348/>>. Acesso em: 02 de Janeiro de 2024. Citado na página 22.
- DATASUS. *Departamento de Informática do SUS. Informações de Saúde, Epidemiológicas e Morbidade: banco de dados*. 2018. Disponível em: <<https://icd.who.int/browse10/2016/en#/I20-I25>>. Acesso em: 02 Janeiro de 2024. Citado na página 14.
- DEY, D. et al. Integrated prediction of lesion-specific ischaemia from quantitative coronary ct angiography using machine learning: a multicentre study. *European radiology*, Springer, v. 28, p. 2655–2664, 2018. Citado na página 15.
- DILSIZIAN, M. E.; SIEGEL, E. L. Machine meets biology: a primer on artificial intelligence in cardiology and cardiac imaging. *Current cardiology reports*, Springer, v. 20, p. 1–7, 2018. Citado na página 15.
- DING, X. et al. Automated coronary artery calcium scoring from non-contrast ct using a patient-specific algorithm. In: SPIE. *Medical Imaging 2015: Image Processing*. [S.l.], 2015. v. 9413, p. 767–772. Citado 2 vezes nas páginas 55 e 56.
- FILIPOIU, F. M. *Atlas of heart anatomy and development*. [S.l.]: Springer Science & Business Media, 2013. Citado na página 22.

- FÖLLMER, B. et al. Active multitask learning with uncertainty-weighted loss for coronary calcium scoring. *Medical Physics*, Wiley Online Library, v. 49, n. 11, p. 7262–7277, 2022. Citado 4 vezes nas páginas 19, 21, 55 e 56.
- GLOROT, X.; BORDES, A.; BENGIO, Y. Deep sparse rectifier neural networks. In: JMLR WORKSHOP AND CONFERENCE PROCEEDINGS. *Proceedings of the fourteenth international conference on artificial intelligence and statistics*. [S.l.], 2011. p. 315–323. Citado na página 27.
- GOGIN, N. et al. Automatic coronary artery calcium scoring from unenhanced-ecg-gated ct using deep learning. *Diagnostic and Interventional Imaging*, Elsevier, v. 102, n. 11, p. 683–690, 2021. Citado 4 vezes nas páginas 19, 21, 55 e 56.
- GONZALEZ, R. C. *Digital image processing*. [S.l.]: Pearson education india, 2009. Citado 2 vezes nas páginas 34 e 35.
- HAN, D. et al. Deep learning analysis in coronary computed tomographic angiography imaging for the assessment of patients with coronary artery stenosis. *Computer Methods and Programs in Biomedicine*, Elsevier, v. 196, p. 105651, 2020. Citado na página 15.
- HECHT, H. et al. Clinical indications for coronary artery calcium scoring in asymptomatic patients: expert consensus statement from the society of cardiovascular computed tomography. *Journal of cardiovascular computed tomography*, Elsevier, v. 11, n. 2, p. 157–168, 2017. Citado na página 15.
- HECHT, H. S. Coronary artery calcium scanning: the key to the primary prevention of coronary artery disease. *Endocrinology and Metabolism Clinics*, Elsevier, v. 43, n. 4, p. 893–911, 2014. Citado na página 14.
- HU, J.; SHEN, L.; SUN, G. Squeeze-and-excitation networks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2018. p. 7132–7141. Citado na página 31.
- IHDAYHID, A. R. et al. Evaluation of an artificial intelligence coronary artery calcium scoring model from computed tomography. *European Radiology*, Springer, v. 33, n. 1, p. 321–329, 2023. Citado 4 vezes nas páginas 20, 21, 55 e 56.
- KAMNITSAS, K. et al. Deepmedic for brain tumor segmentation. In: SPRINGER. *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: Second International Workshop, BrainLes 2016, with the Challenges on BRATS, ISLES and mTOP 2016, Held in Conjunction with MICCAI 2016, Athens, Greece, October 17, 2016, Revised Selected Papers 2*. [S.l.], 2016. p. 138–149. Citado na página 28.
- KJERLAND, Ø. *Segmentation of coronary arteries from CT-scans of the heart using deep learning*. Dissertação (Mestrado) — NTNU, 2017. Citado 3 vezes nas páginas 28, 29 e 41.
- KOO, T. K.; LI, M. Y. A guideline of selecting and reporting intraclass correlation coefficients for reliability research. *Journal of chiropractic medicine*, Elsevier, v. 15, n. 2, p. 155–163, 2016. Citado na página 43.
- LEE, S. et al. Deep-learning-based coronary artery calcium detection from ct image. *Sensors*, MDPI, v. 21, n. 21, p. 7059, 2021. Citado 4 vezes nas páginas 19, 21, 55 e 56.

- LIN, T.-Y. et al. Focal loss for dense object detection. In: *Proceedings of the IEEE international conference on computer vision*. [S.l.: s.n.], 2017. p. 2980–2988. Citado na página 28.
- LOTUFO, P. A.; BENSEÑOR, I. M. Stroke mortality in brazil: one example of delayed epidemiological cardiovascular transition. *International Journal of Stroke*, SAGE Publications Sage UK: London, England, v. 4, n. 1, p. 40–41, 2009. Citado na página 14.
- MARTIN, S. S. et al. Evaluation of a deep learning–based automated ct coronary artery calcium scoring algorithm. *Cardiovascular Imaging*, American College of Cardiology Foundation Washington DC, v. 13, n. 2_Part_1, p. 524–526, 2020. Citado 4 vezes nas páginas 18, 21, 55 e 56.
- MARTIN, S. S. et al. Dyslipidemia, coronary artery calcium, and incident atherosclerotic cardiovascular disease: implications for statin therapy from the multi-ethnic study of atherosclerosis. *Circulation*, Am Heart Assoc, v. 129, n. 1, p. 77–86, 2014. Citado na página 14.
- MELO, E. P. *Ultrassom intracoronário ou OCT: qual o melhor para avaliar a anatomia coronariana?* 2017. Disponível em: <<https://cardiopapers.com.br/ultrassom-intracoronario-ou-oct-qual-o-melhor-para-avaliar-a-anatomia-coronariana>>. Acesso em: 02 Janeiro de 2024. Citado na página 23.
- MONTI, C. B. et al. Machine learning and deep neural networks applications in computed tomography for coronary artery disease and myocardial perfusion. *Journal of thoracic imaging*, LWW, v. 35, p. S58–S65, 2020. Citado na página 15.
- MORI, H. et al. Coronary artery calcification and its progression: what does it really mean? *JACC: Cardiovascular Imaging*, American College of Cardiology Foundation Washington, DC, v. 11, n. 1, p. 127–142, 2018. Citado na página 14.
- MOTWANI, M. et al. Machine learning for prediction of all-cause mortality in patients with suspected coronary artery disease: a 5-year multicentre prospective registry analysis. *European heart journal*, Oxford University Press, v. 38, n. 7, p. 500–507, 2017. Citado na página 16.
- MU, D. et al. Calcium scoring at coronary ct angiography using deep learning. *Radiology*, Radiological Society of North America, v. 302, n. 2, p. 309–316, 2022. Citado 2 vezes nas páginas 19 e 21.
- NABEL, E. G.; BRAUNWALD, E. A tale of coronary artery disease and myocardial infarction. *New England Journal of Medicine*, Mass Medical Soc, v. 366, n. 1, p. 54–63, 2012. Citado 2 vezes nas páginas 22 e 23.
- OEVER, L. B. van den et al. Deep learning for automated exclusion of cardiac ct examinations negative for coronary artery calcium. *European journal of radiology*, Elsevier, v. 129, p. 109114, 2020. Citado 4 vezes nas páginas 19, 21, 55 e 56.
- RIBEIRO, A. L. P. et al. Cardiovascular health in brazil: trends and perspectives. *Circulation*, Am Heart Assoc, v. 133, n. 4, p. 422–433, 2016. Citado 2 vezes nas páginas 14 e 24.

- RODRIGUES, V. *Métricas de Avaliação: acurácia, precisão, recall... quais as diferenças?* 2019. Disponível em: <<https://vitorborbarodrigues.medium.com/m%C3%A9tricas-de-avalia%C3%A7%C3%A3o-acur%C3%A1cia-precis%C3%A3o-recall-quais-as-diferen%C3%A7as-c8f05e0a513c>>. Acesso em: 02 Janeiro de 2024. Citado na página 42.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference, Munich, Germany, October 5–9, 2015, Proceedings, Part III* 18. [S.l.], 2015. p. 234–241. Citado 2 vezes nas páginas 30 e 31.
- SANDLER, M. et al. Mobilenetv2: Inverted residuals and linear bottlenecks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2018. p. 4510–4520. Citado na página 31.
- SHINOHARA, H. et al. Automatic detection of vessel structure by deep learning using intravascular ultrasound images of the coronary arteries. *Plos one*, Public Library of Science San Francisco, CA USA, v. 16, n. 8, p. e0255577, 2021. Citado na página 14.
- SUN, M. et al. Learning pooling for convolutional neural network. *Neurocomputing*, Elsevier, v. 224, p. 96–104, 2017. Citado 2 vezes nas páginas 29 e 30.
- TAN, M.; LE, Q. Efficientnet: Rethinking model scaling for convolutional neural networks. In: PMLR. *International conference on machine learning*. [S.l.], 2019. p. 6105–6114. Citado na página 31.
- TERVEN, J. et al. Loss functions and metrics in deep learning. a review. *arXiv preprint arXiv:2307.02694*, 2023. Citado na página 27.
- THILO, C. et al. Computer-aided stenosis detection at coronary ct angiography: effect on performance of readers with different experience levels. *European radiology*, Springer, v. 25, p. 694–702, 2015. Citado na página 15.
- TOMAR, N. *CT Heart Dataset*. 2022. Disponível em: <<https://www.kaggle.com/datasets/f41e0bab640002775b00e050b81a1144786324951b0576f5d71fd820d6ef13dc>>. Acesso em: 02 Janeiro de 2024. Citado na página 44.
- TSAO, C. W. et al. Heart disease and stroke statistics—2023 update: a report from the american heart association. *Circulation*, Am Heart Assoc, v. 147, n. 8, p. e93–e621, 2023. Citado na página 14.
- ULTRALYTICS. *YOLOv8 Documents*. 2023. Disponível em: <<https://docs.ultralytics.com/pt>>. Acesso em: 02 Janeiro de 2024. Citado na página 46.
- VALENSI, P. et al. Risk stratification and screening for coronary artery disease in asymptomatic patients with diabetes mellitus: Position paper of the french society of cardiology and the french-speaking society of diabetology. *Archives of cardiovascular diseases*, Elsevier, v. 114, n. 2, p. 150–172, 2021. Citado na página 24.
- VELZEN, S. G. van et al. Deep learning for automatic calcium scoring in ct: validation using multiple cardiac ct and chest ct protocols. *Radiology*, Radiological Society of North America, v. 295, n. 1, p. 66–79, 2020. Citado 2 vezes nas páginas 18 e 21.

- VOS, B. D. D. et al. Direct automatic coronary calcium scoring in cardiac and chest ct. *IEEE transactions on medical imaging*, IEEE, v. 38, n. 9, p. 2127–2138, 2019. Citado 4 vezes nas páginas 18, 21, 55 e 56.
- WANG, W. et al. Coronary artery calcium score quantification using a deep-learning algorithm. *Clinical Radiology*, Elsevier, v. 75, n. 3, p. 237–e11, 2020. Citado na página 14.
- WARRENS, M. J. Cohen’s linearly weighted kappa is a weighted average. *Advances in Data Analysis and Classification*, Springer, v. 6, n. 1, p. 67–79, 2012. Citado na página 43.
- WISDOMML. *EfficientNet and its Performance Comparison with Other Transfer Learning Networks*. 2023. Disponível em: <<https://wisdomml.in/efficientnet-and-its-performance-comparison-with-other-transfer-learning-networks/>>. Acesso em: 02 Janeiro de 2024. Citado na página 32.
- WOLTERINK, J. M. et al. An evaluation of automatic coronary artery calcium scoring methods with cardiac ct using the orcascore framework. *Medical physics*, Wiley Online Library, v. 43, n. 5, p. 2361–2373, 2016. Citado 2 vezes nas páginas 40 e 44.
- YOSHIDA, A. et al. Automated heart segmentation using u-net in pediatric cardiac ct. *Measurement: Sensors*, Elsevier, v. 18, p. 100127, 2021. Citado 5 vezes nas páginas 31, 32, 35, 45 e 46.
- ZHANG, W. et al. An end-to-end joint learning framework of artery-specific coronary calcium scoring in non-contrast cardiac ct. *Computing*, Springer, v. 101, p. 667–678, 2019. Citado 4 vezes nas páginas 18, 21, 55 e 56.
- ZHENG, Y.; TEK, H.; FUNKA-LEA, G. Robust and accurate coronary artery centerline extraction in cta by combining model-driven and data-driven approaches. In: SPRINGER. *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2013: 16th International Conference, Nagoya, Japan, September 22–26, 2013, Proceedings, Part III* 16. [S.l.], 2013. p. 74–81. Citado na página 55.