

UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
COMPUTAÇÃO

FERNANDA AMBROGI BARBOSA DA LUZ

**Detecção de artefatos em cintilografia miocárdica
utilizando inteligência artificial**

GOIÂNIA
18 de junho de 2025



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do material bibliográfico

Dissertação Tese Outro*: _____

*No caso de mestrado/doutorado profissional, indique o formato do Trabalho de Conclusão de Curso, permitido no documento de área, correspondente ao programa de pós-graduação, orientado pela legislação vigente da CAPES.

Exemplos: Estudo de caso ou Revisão sistemática ou outros formatos.

2. Nome completo do auto

FERNANDA AMBROGI BARBOSA DA LUZ

3. Título do trabalho

“Detecção de artefatos em cintilografia miocárdica utilizando inteligência artificial”

4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento SIM NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

a) consulta ao(à) autor(a) e ao(à) orientador(a);

b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação. O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Wesley Pacheco Calixto**, Usuário Externo, em 22/07/2025, às 09:51, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fernanda Ambrogi Barbosa Da Luz, Discente**, em 22/07/2025, às 10:25, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5515519** e o código CRC **C40F1F36**.

Referência: Processo nº 23070.020705/2025-81

SEI nº 5515519

FERNANDA AMBROGI BARBOSA DA LUZ

Detecção de artefatos em cintilografia miocárdica utilizando inteligência artificial

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação, da Faculdade Engenharia Elétrica, Mecânica e Computação, da Universidade Federal de Goiás (UFG), como requisito para obtenção do título de Mestra em Engenharia Elétrica e Computação.

Área de concentração: Engenharia de computação.

Orientador: Professor Doutor Wesley Pacheco Calixto.

Coorientadora: Professora Doutora Solange Amorim Nogueira.

GOIÂNIA

18 de junho de 2025

Copyright © 18 de junho de 2025 by Federal University of Goiás - UFG, Brazil. No part of this publication may be reproduced, stored in a retrieval system, or transmitted in any form or by any means, electronic, mechanical, photocopying, microfilming, recording or otherwise, without written permission from the Library of UFG, with the exception of any material supplied specifically for the purpose of being entered and executed on a computer system, for exclusive use of the reader of the work.

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Luz, Fernanda Ambrogi Barbosa da
Detecção de artefatos em cintilografia miocárdica utilizando inteligência artificial [manuscrito] / Fernanda Ambrogi Barbosa da Luz. - 2025.
XCIX, 99 f.: il.

Orientador: Profa. Dra. Wesley Pacheco Calixto; co-orientadora Dra. Solange Amorim Nogueira.
Dissertação (Mestrado) - Universidade Federal de Goiás, Escola de Engenharia Elétrica, Mecânica e de Computação (EMC), Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Goiânia, 2025.

Bibliografia.

Inclui siglas, abreviaturas, símbolos, gráfico, tabelas, lista de figuras, lista de tabelas.

1. Artefatos. 2. Cintilografia Miocárdica. 3. Aprendizado Profundo. 4. nn-Unet. I. Calixto, Wesley Pacheco , orient. II. Título.

CDU 004



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

ATA EMC 15/2025

ATA DE DEFESA DE DISSERTAÇÃO

Ata nº 15 da sessão de Defesa de Dissertação de **Fernanda Ambrogi Barbosa da Luz**, que confere o título de Mestra em **Engenharia Elétrica e de Computação** na área de concentração em **Engenharia de Computação**.

Aos dezoito dias do mês de junho, a partir das 14h00min, por vídeoconferência, realizou-se a sessão pública de Defesa de Dissertação intitulada “**Deteção de artefatos em cintilografia miocárdica utilizando inteligência artificial**”. Os trabalhos foram instalados pelo Orientador, Professor Doutor **Wesley Pacheco Calixto - (EMC/UFG)**, com a participação dos demais membros da Banca Examinadora: Professora Doutora **Solange Amorim Nogueira (HIAE/BIOMED)**, Coorientadora; Professora Doutora **Lilian Yuri Itaya Yamaga (HIAE/BIOMED)**, Membro Titular Externo; Professor Doutor **Antônio Paulo Mendes Breda Dias Coimbra (UC, Portugal/ENG)**, Membro Titular Externo; Professor Doutor **Márcio Rodrigues da Cunha Reis (ELE/UTFPR)** Membro Titular Externo; Professor Doutor **Rodrigo Pinto Lemos (EMC/UFG)**, Membro Titular Interno. Durante a arguição os membros da banca **não fizeram** sugestão de alteração do título do trabalho. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Dissertação, tendo sido a candidata **aprovada** pelos seus membros. Proclamados os resultados pelo Professor Doutor **Wesley Pacheco Calixto**, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos dezoito dias do mês de junho de dois mil e vinte e cinco.

TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **Fernanda Ambrogi Barbosa Da Luz, Discente**, em 13/08/2025, às 11:09, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Wesley Pacheco Calixto, Usuário Externo**, em 13/08/2025, às 21:01, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **SOLANGE AMORIM NOGUEIRA, Usuário Externo**, em 13/08/2025, às 23:12, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **LILIAN YURI ITAYA YAMAGA, Usuário Externo**, em 14/08/2025, às 12:14, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Márcio Rodrigues Da Cunha Reis**, **Usuário Externo**, em 15/08/2025, às 08:07, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Rodrigo Pinto Lemos**, **Professor do Magistério Superior**, em 15/08/2025, às 14:00, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Antônio Paulo Mendes Breda Dias Coimbra**, **Usuário Externo**, em 02/09/2025, às 07:59, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5568722** e o código CRC **7F3DCE29**.

“Renda-se, como eu me rendi. Mergulhe no que você não conhece como eu mergulhei. Não se preocupe em entender, viver ultrapassa qualquer entendimento.”

CLARICE LISPECTOR

Dedico este trabalho à minha família pelo apoio, amor e incentivo constantes ao longo desta jornada.

AGRADECIMENTOS

”Mas graças a Deus, que sempre nos conduz vitoriosamente em Cristo e por nosso intermédio exala em todo lugar a fragrância do seu conhecimento”2 Coríntios 2:14.

E desta forma começo o agradecimento, ”Obrigada, Deus!”

Obrigada a todos da minha família que desde sempre apoiam meu crescimento pessoal e profissional com amor incondicional; Em especial, ao meu tio Gilberto (in memoriam), que nunca deixou de demonstrar seu carinho e orgulho.

Obrigada aos que me mostram todos os dias o quão admirável e inspirador pode ser a determinação e o aprimoramento profissional de um amigo;

Obrigada a Renata que me transferiu esta oportunidade de desenvolvimento, ao lado de grandes conhecedores e orientada e coorientada por expoentes admiráveis da área, Prof. Wesley Pacheco, Prof^a. Dr^a. Solange Amorim e M.Sc. Thiago Ortiz. Meu respeito e gratidão!

Obrigada a cada integrante da minha equipe, todos foram fundamentais para o desenvolvimento deste projeto.

Obrigada a minha chefe Taise e sêniores que sempre se dispuseram a ajudar, principalmente com os horários das disciplinas e a equipe da Medicina Nuclear pelo interesse e torcida.

Além desta dissertação marcar período de dedicação e trabalho árduo, também representa o início de novas possibilidades e oportunidades de crescimento.

Obrigado a todos por fazerem parte desta jornada.

RESUMO

Este trabalho propõe o uso de técnicas de inteligência artificial, especificamente redes neurais convolucionais e nnU-Net, para aprimorar a identificação de artefatos em imagens de cintilografia de perfusão miocárdica, visando auxiliar a equipe técnica na avaliação inicial da qualidade de imagem no exame em questão. A metodologia incluiu a coleta de dados em ambiente clínico, seguida pela preparação e análise dos dados utilizando a Plataforma 3D Slicer para segmentação manual do ventrículo esquerdo na primeira etapa até aplicação e validação dos modelos por meio da nnU-Net. O projeto seguiu para uma segunda fase com a segmentação manual dos artefatos e nova aplicação de modelos de IA para a segmentação automatizada, com foco na precisão da identificação de artefatos em cintilografia miocárdica. Com os resultados preliminares da segmentação do ventrículo esquerdo demonstrados por meio da validação interna, com coeficiente de Dice $D_c = 87\%$ e $\sigma \pm 6\%$ e validação externa de $D_c = 88,46\%$ com desvio padrão de $\sigma \pm 7,48\%$ e concordância de pelo menos 80% das segmentações realizadas, o processo continua com as segmentações dos artefatos. Como resultado final, obtivemos a aplicação de diferentes modelos de otimização com coeficiente de Dice variando entre 0,300 a 0,940, limiar de 0,853, área sob a curva ROC foi AUC= 0,946, especificidade perfeita em todos os cenários e sensibilidade modesta indicando que o modelo tende a não sinalizar alguns casos de interferência entre artefatos e ventrículo esquerdo. Além disso, a validação externa com médicos especialistas demonstrou valor superior a 60% de concordância entre as máscaras realizadas pelo especialista e pelo modelos de IA demonstrando a utilidade e assistência que o uso de modelos computacionais aplicadas na prática médica podem exercer para equipe assistencial.

Palavras-chave: Artefatos; Cintilografia miocárdica; Aprendizado Profundo; nnU-Net.

ARTIFACT DETECTION IN MYOCARDIAL SCINTIGRAPHY USING ARTIFICIAL INTELLIGENCE

ABSTRACT

This work proposes the use of artificial intelligence techniques, specifically convolutional neural networks and nnU-Net, to enhance the identification of artifacts in myocardial perfusion scintigraphy images, with the goal of assisting the technical team in the initial assessment of image quality for the exam in question. The methodology involved data collection in a clinical setting, followed by data preparation and analysis using the 3D Slicer platform for manual segmentation of the left ventricle in the initial stage, culminating in the application and validation of the models using nnU-Net. The project then progressed to a second phase, which included manual segmentation of artifacts and a new application of AI models for automated segmentation, with a focus on improving the precision of artifact identification in myocardial perfusion scintigraphy. Based on the preliminary results of the left ventricular segmentation demonstrated by internal validation, with Dice coefficient $D_c = 87\%$ and $\sigma \pm 6\%$ and external validation of $D_c = 88.46\%$ with standard deviation of $\sigma \pm 7.48\%$ and agreement of at least 80% of the segmentations performed, the process continues with the artifact segmentations. As a final result, we obtained the application of different optimization models with a Dice coefficient ranging from 0.300 to 0.940, a threshold of 0.853, the area under the ROC curve was $AUC = 0.946$, perfect specificity in all scenarios and modest sensitivity, indicating that the model tends not to signal some cases of interference between artifacts and the left ventricle. Furthermore, external validation with specialist doctors demonstrated a value of more than 60% agreement between the masks made by the specialist and the AI models, demonstrating the usefulness and assistance that the use of computational models applied in medical practice can provide to the healthcare team.

Keywords: Artifacts; Myocardial scintigraphy; nnU-net; Deep learning.

SUMÁRIO

Pág.

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE SÍMBOLOS

LISTA DE ABREVIATURAS E SIGLAS

CAPÍTULO 1 INTRODUÇÃO	27
CAPÍTULO 2 ENFERMIDADE CARDÍACA	35
2.1 Panorama clínico da doença arterial coronariana	35
2.2 Aplicação e desempenho da cintilografia de perfusão miocárdica	36
2.3 Desafios técnicos na cintilografia de perfusão miocárdica	39
2.4 Considerações finais	41
CAPÍTULO 3 APLICAÇÃO DE SISTEMAS COMPUTACIONAIS	43
3.1 Infraestrutura computacional e integração da inteligência artificial em imagens médicas	43
3.2 Inteligência Artificial	45
3.3 Funcionamento da nnU-Net	46
3.4 Considerações finais	47
CAPÍTULO 4 METODOLOGIA	49
4.1 Contextualização	49
4.2 Protocolo para realização do exame	50
4.3 Gestão dos dados	51
4.4 Modelo de predição das paredes do ventrículo esquerdo: Fase I	53
4.5 Identificação dos artefatos: Fase II	54
4.6 Aquisição e preparação dos dados clínicos	55
4.7 Desenvolvimento e validação do modelo supervisionado	57
4.8 Fusão de classes e definição da região do artefato inviabilizante	58
4.9 Validação e integração clínica do modelo proposto	59

4.10	Considerações finais	61
CAPÍTULO 5 RESULTADOS		63
5.1	Obtenção e pré-tratamento dos dados	63
5.2	Treinamento e validação interna do modelo de predição: Fase I	65
5.3	Validação externa do sistema: Fase I	67
5.4	Obtenção e pré-tratamento dos dados clínicos para Fase II	71
5.5	Avaliação preditiva da interferência diagnóstica	75
5.6	Validação externa e avaliação clínica: fase II	78
5.7	Discussão	80
5.7.1	Comparação com a literatura e avanços metodológicos	81
5.7.2	Limitações e propostas de aprimoramento	83
5.7.3	Perspectivas futuras	85
CAPÍTULO 6 CONCLUSÃO		87
6.1	Contribuição do trabalho	88
REFERÊNCIAS BIBLIOGRÁFICAS		89

LISTA DE FIGURAS

	<u>Pág.</u>	
2.1	Projeções do miocárdio visualizadas no exame: eixo curto, eixo longo horizontal e eixo longo vertical.	38
2.2	Aquisição em SPECT do exame de Cintilografia de Perfusão do Miocárdio. O estudo revela concentração homogênea do indicador no miocárdio durante as etapas de esforço e repouso, indicando a ausência de elementos sugestivos de isquemia regional nos cortes tomográficos estudados.	38
2.3	Artefato em forma de banana relacionado ao posicionamento do paciente influenciando no (A) eixo curto do ventrículo esquerdo com hipercaptação em região septal e (B) segmentos do mapa polar.	41
3.1	Arquitetura clássica da rede nnU-net.	46
4.1	Fluxograma da metodologia proposta da Fase I.	50
4.2	Fluxograma da metodologia proposta da Fase II.	56
5.1	Segmentação manual dos ventrículo esquerdo produzida na Plataforma 3D Slicer.	65
5.2	Curva de <i>Dice</i> com a distribuição das pontuações na validação interna do modelo no subconjunto de teste.	67
5.3	Corte tomográfico do ventrículo esquerdo no eixo longo: (a) original, (b) segmentação manual, (c) segmentação com a metodologia proposta e (d) sobreposição da Figura 5.3(b) e Figura 5.3(c).	68
5.4	Curva de <i>Dice</i> com a distribuição das pontuações na validação externa do sistema.	69
5.5	Imagens encaminhadas para os M_N encarregados da avaliação de concordância entre as segmentações da IA e especialista biomédico.	70
5.6	<i>Boxplot</i> da métrica D_c para cada modelo nas Classe 1 e Classe 2	74
5.7	Comparação visual entre segmentações manual e automatizada em três exames distintos.	79

LISTA DE TABELAS

	<u>Pág.</u>
1.1 Alguns dos trabalhos mencionados que abordam o uso de aprendizado profundo em exames cardiológicos.	33
5.1 Características demográficas dos participantes.	64
5.2 Avaliação médica geral dos 9 conjuntos de imagens apresentada aos médicos.	70
5.3 Avaliação médica individual por teste.	71
5.4 Valores otimizados para os limiares de cada variante da nnU-Net.	73
5.5 Desempenho da regressão logística no conjunto de teste.	77
5.6 Grau de concordância das máscaras respondidas pelos especialistas por tipo de segmentação.	78
5.7 Avaliação médica individual por teste.	80

LISTA DE SÍMBOLOS

μ	– Média
σ	– Desvio padrão
k -folds	– Validação cruzada
DB_1	– Banco de dados um
DB_2	– Banco de dados dois
DB_3	– Banco de dados três
DB_4	– Banco de dados quatro
D_c	– Coeficiente de <i>Dice</i>
F	– Feminino
I_N	– Identificação do número do paciente
keV	– quiloelétron-volt
M	– Masculino
MBq/kg	– Megabecquerel por quilograma
Min	– Trajetória referência
MN_1	– Médico especialista em medicina nuclear um
MN_2	– Médico especialista em medicina nuclear dois
MN_3	– Médico especialista em medicina nuclear três
mm	– Milímetro
N	– Número total de pacientes
px	– Unidade de <i>pixel</i>

LISTA DE ABREVIATURAS E SIGLAS

201Tl	–	Tálio 201
99mTc	–	Tecnécio
AC	–	Angiografia coronariana
ACC	–	acurácia
APP	–	Aplicação ou programa de aplicação
AP	–	Aprendizagem profunda
ATC	–	Angiotomografia coronariana
AUPR	–	Precisão-revocação
AWS	–	<i>Amazon Web Service</i>
CA	–	Correção de atenuação
CAAE	–	Certificado de apresentação de apreciação ética
CNN	–	<i>Convolutional neural network</i>
CPM	–	Cintilografia de perfusão do miocárdio
CZT	–	Cadmio-zinco-telureto
DAC	–	Doença arterial coronariana
DCV	–	Doença cardiovasculares
DICOM	–	<i>Digital imaging and communications in medicine</i>
DLAC	–	Correção de atenuação de aprendizagem profunda
DPT	–	Déficit de perfusão Total
DsM	–	<i>Dataset manager</i>
EAC	–	Estenose de artéria carótida
EC	–	Eixo curto
EC2	–	<i>Elastic compute cloud</i>
ECG	–	Ecocardiograma
ELH	–	Eixo longo horizontal
ELV	–	Eixo longo vertical
GAN	–	<i>Generative adversarial networks</i>
IA	–	Inteligencia artificial
IAM	–	Infarto agudo do miocárdio
ID	–	Identidade do paciente
IoU	–	Intersecção sobre união
JSON	–	<i>JavaScript object notation</i>
MIBI	–	Tetrafluoroborato tetramibi cuproso
MIBI- 99mTc	–	Tetrafluoroborato tetramibi cuproso marcado com tecnécio
nnU-Net	–	No-New-U-Net
OSEM	–	<i>Subset expectation maximization</i>
PACS	–	<i>Picture archiving and communication system</i>
PRE	–	Precisão

REDCap	–	<i>Research electronic data capture</i>
RMC	–	Ressonância magnética cardíaca
RNC	–	Rede Neural Convulacional
ROC	–	<i>Receiver operating characteristic curve</i>
S3 MinIO	–	<i>Simple storage service</i> (Amazon S3)
SEN	–	Sensibilidade
SPE	–	Especificidade
SPECT	–	<i>Single-photon emission computed tomography</i>
SPECT _{DL}	–	<i>Single-photon emission computed tomography - deep learning</i>
SVM	–	<i>Support Vector Machine</i>
TC	–	Tomografia computadorizada
TCLE	–	Termo de consentimento livre e esclarecido
TPS	–	<i>Total perfusion scintigraphy</i>
U-NET	–	<i>Convolutional neural network architecture in a U-shaped format</i>
UFG	–	Universidade Federal de Goiás
VE	–	Ventrículo esquerdo
VNA	–	<i>Vendor Neutral Archive</i>

CAPÍTULO 1

INTRODUÇÃO

Abordagens seguras para diagnóstico e estratificação de risco são relevantes na condução clínica da doença arterial coronariana (DAC), uma das principais causas de mortalidade no mundo. Embora a angiografia coronariana permaneça como referência, técnicas de imagem não invasivas representam alternativas valiosas (NOGUEIRA *et al.*, 2025; R. *et al.*, 2020). Entre estas, destacam-se a cintilografia de perfusão do miocárdio (CPM), a ecocardiografia sob estresse, a angiotomografia computadorizada coronariana e a ressonância magnética cardíaca (DOWSLEY *et al.*, 2013; LI; KRONENBERG, 2021; CHEN *et al.*, 2022), cada uma com aplicações específicas na detecção de estenoses e na avaliação do risco cardiovascular (DAVID *et al.*, 2024). A seleção da técnica mais adequada depende das condições clínicas do paciente, da indicação médica e da infraestrutura tecnológica disponível (DOWSLEY *et al.*, 2013).

Técnicas computacionais avançadas têm ampliado o potencial diagnóstico por meio da integração de diferentes modalidades de imagem (LIN *et al.*, 2021; R. *et al.*, 2019). Neste contexto, a CPM destaca-se por sua elevada sensibilidade e especificidade, sobretudo quando associada à tomografia por emissão de fóton único sincronizada ao eletrocardiograma (gated SPECT) (D.; LESLEE, 2006; NUDI *et al.*, 2017). Apesar do avanço de outras técnicas, como a angiotomografia e a ressonância magnética cardíaca, a CPM apresenta vantagens na análise funcional do miocárdio (WEBERLING *et al.*, 2022). A CPM é útil na visualização das funções biológicas e perfusão celular, oferecendo suporte no diagnóstico e tratamento da DAC. Este procedimento utiliza o radiofármaco tetrafluorborato tetramibi cuproso (^{99m}Tc -MIBI) como principal traçador de perfusão miocárdica, sendo as imagens adquiridas por equipamentos com detectores de telureto de cádmio e zinco (CZT) (KIKUCHI *et al.*, 2022). No entanto, sua acurácia pode ser comprometida pela presença de artefatos relacionados a fatores clínicos, limitações técnicas ou características do equipamento utilizado (S.; A., 2006; MITITELU *et al.*, 2021).

Diante destas limitações, inovações tecnológicas têm buscado aprimorar a confiabilidade da CPM. Detectores de CZT aumentam a qualidade das imagens e reduzem a exposição à radiação (BEN-HAIM *et al.*, 2016; ANAGNOSTOPOULOS *et al.*, 2011), oferecendo maior sensibilidade e resolução energética em relação às tecnologias convencionais (BUECHEL *et al.*, 2010; BEN-HAIM *et al.*, 2016). Ainda assim, a ocorrência

de artefatos persiste como desafio técnico, exigindo rigor nas etapas de aquisição, processamento e interpretação (E., 1994; MITITELU et al., 2021).

Além dos aprimoramentos em hardware, como os detectores de CZT, avanços em algoritmos computacionais, especialmente por meio de técnicas de aprendizado profundo (AP), têm potencializado a análise de imagens cardiovasculares, otimizando o diagnóstico e a estratificação de risco da DAC (LIN et al., 2021; DEY et al., 2019). No contexto da CPM, modelos com *deep learning* (DL) apresentam maior acurácia diagnóstica em comparação a métodos quantitativos tradicionais e avaliações visuais conduzidas por especialistas (OTAKI et al., 2022; PAPANDRIANOS; PAPAGEORGIU, 2021). Estas abordagens com inteligência artificial (IA) possibilitam a análise automática de imagens de SPECT, aprimorando a detecção de anormalidades de perfusão e DAC obstrutiva (LIU et al., 2021; ALSKAF et al., 2022). Além disto, modelos preditivos que integram dados de SPECT, com ou sem informações demográficas, apresentam melhoria na previsão prognóstica de pacientes com DAC (CICEK et al., 2024).

A incorporação da IA aplicável em softwares clínicos facilita sua aceitação e implementação nos fluxos de trabalho convencionais, promovendo maior confiabilidade e transparência na tomada de decisão médica (OTAKI et al., 2022). Com a evolução das tecnologias de IA, prevê-se impacto positivo na eficiência, na redução de custos e na personalização do atendimento em imagem cardiovascular (PAPANDRIANOS et al., 2022; GOMEZ; DOUKKY, 2019). Estudos apresentam o potencial das técnicas de DL e aprendizado de máquina (*machine learning* – ML) na otimização da interpretação da CPM para a detecção da DAC. Redes neurais convolucionais profundas apresentam desempenho superior à análise tradicional do déficit total de perfusão (*total perfusion deficit* – TPD) na predição de DAC obstrutiva, tanto em nível individual (*per-patient*) quanto vascular (*per-vessel*) (BETANCUR et al., 2018c; BETANCUR et al., 2018a).

Além disto, algoritmos de ML que integram variáveis clínicas, dados de teste ergométrico e imagens, superam a interpretação de especialistas e a análise quantitativa por TPD na predição da necessidade de revascularização coronariana precoce (HU et al., 2019). Modelos com máquinas de vetores de suporte (*Support Vector Machine* – SVM), que combinam informações de perfusão e variáveis funcionais, apresentam maior acurácia diagnóstica em comparação à avaliação visual convencional (ARSANJANI et al., 2013). Estes métodos computacionais avançados demonstram sensibi-

lidade, especificidade e precisão diagnóstica superiores em relação às abordagens quantitativas e visuais tradicionais (PRASAD et al., 2010; IOANNIS et al., 2020; ARSANJANI et al., 2013). A incorporação de técnicas de IA à cardiologia nuclear tem potencial para aprimorar a capacidade diagnóstica da CPM, proporcionando maior precisão e eficiência na detecção da DAC (GOMEZ; DOUKKY, 2019).

A literatura científica investiga também diferentes abordagens de DL para aprimorar a qualidade das imagens, a detecção de defeitos de perfusão e a segmentação de estruturas na CPM com SPECT. Técnicas de redução de ruído com DL, como redes neurais convolucionais (*convolutional neural networks* – CNN) e arquiteturas inspiradas em U-Net, apresentam maior eficiência na atenuação do ruído e na identificação de defeitos de perfusão, superando os métodos convencionais de pós-filtragem (LIU et al., 2020; RAMON et al., 2020).

Estas abordagens possibilitam a redução da dose de radiação sem comprometer a acurácia diagnóstica (LIU et al., 2021; PRETORIUS et al., 2021). Comparações entre métodos de redução de ruído pós-reconstrução e reconstrução com DL indicam equilíbrio entre suavidade da imagem e desempenho na detecção de defeitos de perfusão (SOHLBERG et al., 2023). Embora as técnicas com DL geralmente superem os métodos tradicionais, alguns estudos indicam que, visualmente, os defeitos de perfusão podem parecer mais profundos em imagens reconstruídas sem estas técnicas, especialmente em protocolos de baixa dose. No geral, os métodos de redução de ruído com DL apresentam potencial para aprimorar a qualidade das imagens de CPM com SPECT e a precisão diagnóstica, particularmente em cenários de baixa dose (WANG et al., 2010).

Liu et al. (2020) aplicam Redes Neurais Convolucionais (RNC), que é um tipo específico de AP, em imagens cardíacas obtidas por tomografia computadorizada de emissão de fóton único (SPECT) para aprimorar a precisão diagnóstica da DAC. A RNC é desenvolvida, treinada e validada para realizar diagnóstico automático de anormalidades em exames de CPM sob estresse. A análise da curva característica de operação do receptor (ROC) para todos os pacientes do estudo apresenta que a RNC é mais precisa que o método quantitativo atualmente empregado. Nos subgrupos analisados, apresenta-se maior consistência com menor variação em relação ao valor padrão, alta acurácia e especificidade, embora tenha menor sensibilidade. A incorporação da RNC durante o estágio de esforço melhora a precisão e consistência na detecção de anormalidades perfusionais no exame de CPM.

[Betancur et al. \(2018b\)](#) apresentam modelo de RNC com potencial para aprimorar a interpretação automatizada de exames de CPM. Este estudo multicêntrico compara os resultados obtidos pela RNC com os resultados da avaliação de déficit de perfusão total (DPT), que é a metodologia quantitativa atualmente utilizada para avaliar a perfusão na fase de estresse e repouso. Os pacientes participantes são submetidos à etapa de esforço sem conhecimento prévio do diagnóstico de DAC e com angiografia coronariana realizada em até 180 dias da CPM. A RNC é treinada com dados brutos e mapas polares, sendo submetida a validação cruzada. Os resultados apresentam que a análise por paciente e por obstrução vascular demonstra maior sensibilidade e especificidade com o uso da RNC em comparação com a DPT. Isto resulta em aproximadamente 62% dos pacientes com DAC e 37% dos vasos obstruídos, sendo 43,7% na descendente anterior esquerda, 33% no ramo da circunflexa e 33% no ramo da coronária direita.

[Liu et al. \(2021\)](#) investigam o potencial da RNC para aprimorar a detecção de defeitos de perfusão em imagens médicas adquiridas com dose padrão. Após treinarem e validarem a RNC, os autores aplicam a curva ROC nas imagens reconstruídas usando a técnica Máxima Expectativa de Subconjunto Ordenado (OSEM), correção de atenuação, resolução e dispersão, além de pós-filtragem gaussiana 3D, tanto com aplicação de RNC quanto sem a aplicação da RNC, com o intuito de quantificar a detecção de defeitos de perfusão. Os resultados indicam que o filtro de RNC aplicado após a reconstrução pode aprimorar a precisão na detecção das imagens, mesmo quando os defeitos apresentam baixo contraste, em comparação à pós-filtragem gaussiana. Além disto, a RNC contribui para reduzir ruídos, permitindo reconstrução com menos filtros de pós-processamento e, conseqüentemente, resultando em maior resolução no ventrículo esquerdo.

O estudo realizado por [Olia et al. \(2022\)](#) emprega a AP Generative Adversarial Network (GAN) para viabilizar a redução de atividade¹ do radiofármaco administrado para obtenção de imagens SPECT no exames de cintilografia de perfusão do miocárdio preservando a qualidade, acurácia e valor clínico das imagens resultantes. A abordagem se apresenta eficaz na redução de ruídos em imagens com reduções de 50% e 25% da atividade administrada. Contudo, imagens com redução de 12,5% da atividade não demonstraram viabilidade, devido à baixa relação sinal-ruído, impactando negativamente na interpretação clínica. Por outro lado, o trabalho [Hagio et al.](#)

¹Quantidade de radiofármaco geralmente marcado, que é injetado no paciente para a realização do exame ([KAPUCU et al., 2009](#)).

(2022) desenvolve o algoritmo para fornecer correção de atenuação de aprendizagem profunda virtual (*Deep Learning Attenuation-Corrected* - DLAC), com o intuito de realizar atenuação nos mapas polares, dispensando a necessidade de exames de TC ou varreduras adicionais. Os resultados apresentam que a correção de atenuação realizada pela DLAC desenvolvida é comparável à obtida com a TC, aumentando a acurácia diagnóstica quando comparada a imagens de perfusão sem correção de atenuação.

Yang et al. (2021) empregam AP para gerar imagens de cintilografia miocárdica SPECT com correção de atenuação ($SPECT_{DL}$), partindo de imagens SPECT corrigido por TC. A avaliação da acurácia do $SPECT_{DL}$ em relação ao SPECT corrigido por TC leva em consideração o tamanho do voxel² e a análise segmentar. Embora a observação dos mapas polares indiquem redução dos artefatos, o desempenho do $SPECT_{DL}$ não se apresenta uniforme em todos os objetos de estudo, devido às variações nas atenuações e padrões de captação do radiofármaco. A abordagem com $SPECT_{DL}$ reduz os artefatos quando comparada ao SPECT corrigido por TC, no entanto, há a necessidade de mais estudos para assegurar a aplicação clínica. (KIKUCHI et al., 2022) propõem a utilização de duas arquiteturas de AP, U-Net e U-Net++, para a extração de regiões miocárdicas a partir de reconstruções transaxiais com entrada de múltiplas fatias e, assim, reduzir os efeitos da atividade extracardíaca. Através do coeficiente de Dice³, o sistema com base em U-Net++ com entrada de múltiplas fatias apresenta alta acurácia na extração do miocárdio e eficácia na redução dos efeitos da atividade extracardíaca em imagens SPECT.

Outros estudos, como o realizado por El-Taraboulsi et al. (2023), têm explorado diversas arquiteturas de RNC para aprimorar a segmentação cardíaca em imagens médicas, componente necessário para diagnóstico e tratamento personalizado. Embora tenham identificado lacunas nas tecnologias atuais e apontado para a necessidade de futuras pesquisas, destacam que a arquitetura U-Net é amplamente adotada para esta finalidade, enquanto o modelo No-New-U-Net (nnU-net) se destaca devido à sua alta precisão. Zhu et al. (2022) conduzem estudo com 93 pacientes submeti-

²O termo voxel é a abreviação de elemento volumétrico e representa valor de intensidade em espaço tridimensional. A contagem de voxels é o processo de quantificar o número de unidades tridimensionais de volume dentro da região de interesse. É abordagem objetiva e automatizada que auxilia os profissionais de saúde na análise e no acompanhamento de lesões, proporcionando informações valiosas para o diagnóstico e tratamento (GLASSNER, 1984; ASHBURNER; FRISTON, 2000).

³Coefficiente de Dice é utilizada para avaliar a sobreposição ou concordância entre regiões em análises de imagens (KIKUCHI et al., 2022).

dos a angiografia por tomografia computadorizada para investigar o desempenho do modelo nnU-Net na detecção e segmentação de placas arterioscleróticas na artéria carótida. Os resultados demonstram que o modelo nnU-Net oferece desempenho satisfatório, com validação comprovada, destacando sua utilidade no diagnóstico da estenose da artéria carótida e na segmentação das placas ateroscleróticas carotídeas por meio de angiografia por tomografia computadorizada.

[Apostolopoulos et al. \(2023\)](#) destacam os avanços recentes no uso de AP em imagens de SPECT cardíaco, resumindo 52 estudos em cinco categorias distintas: i) classificação de doenças, ii) redução de ruído, iii) correção de atenuação, iv) estimativa de contagem no SPECT e v) reconstrução. Os resultados apontam que os métodos com base em AP alcançam níveis de concordância com especialistas, superando as abordagens quantitativas tradicionais. Além disto, eles se apresentam eficazes para diagnóstico não invasivo de doenças cardiovasculares, contribuindo significativamente para a melhoria da qualidade das imagens e destacando-se nas correções de atenuação. A Tabela 1.1 dispõe a síntese dos estudos, organizados em ordem cronológica, indicando a crescente relevância do uso de AP em exames cardiológicos.

A literatura existente aborda amplamente o uso de IA na análise de imagens médicas, especialmente para diagnóstico e prognóstico da DAC. Entretanto, há escassez de estudos que explorem a aplicação da IA para a identificação de artefatos em imagens de CPM, os quais podem comprometer a precisão do exame e levar a diagnósticos incorretos. A identificação precisa de artefatos em CPM pode otimizar a qualidade das imagens e, conseqüentemente, melhorar a interpretação clínica. O uso de CNN, especialmente a nnU-Net, pode viabilizar a segmentação mais precisa dos artefatos, permitindo que a equipe técnica intervenha precocemente para reduzir a ocorrência de imagens comprometidas. Além disto, a pesquisa contribui para a implementação de soluções automatizadas no fluxo clínico, facilitando a adoção da IA na prática médica.

Diante desta lacuna, este estudo tem como objetivo desenvolver e avaliar modelo de IA para a identificação automática de artefatos em imagens de CPM antes do processamento, com o intuito de aprimorar a qualidade das imagens e otimizar o fluxo de trabalho. Para isto, propõem-se os seguintes objetivos específicos: i) coletar e preparar dados clínicos de exames de CPM, garantindo a segmentação manual inicial do ventrículo esquerdo e posteriormente dos artefatos, ii) implementar e otimizar a rede neural convolucional (CNN) nnU-Net para segmentação automatizada dos

Tabela 1.1 - Alguns dos trabalhos mencionados que abordam o uso de aprendizado profundo em exames cardiológicos.

Proposta/Abordagem	Referência	Contexto/Descrição
Correção de atenuação direta usando AP para imagens SPECT em CPM	Yang et al. (2021)	Demonstra técnica de CA direta usando AP para imagens de perfusão miocárdica.
Utilização da nnU-net para angiografia por ATC no auxílio à avaliação de estenose da artéria carótida e placa aterosclerótica.	Zhu et al. (2022)	Verifica modelo com base em nnU-Net para imagens de ATC no auxílio à avaliação de estenose da artéria carótida e placa aterosclerótica.
Redução da dose na imagem de perfusão miocárdica por SPECT	Olia et al. (2022)	Modelo de AP para avaliar diferentes níveis de atividade em imagens reduzida prevendo dados de projeção de atividade padrão.
Extração de região miocárdica de imagens SPECT por AP	Kikuchi et al. (2022)	Extração automática de regiões miocárdicas de imagens SPECT usando AP para reduzir os efeitos da atividade extra-cardíaca com problemática em imagens nucleares cardíacas
Modelos de AP para segmentação de imagens cardíacas	El-Taraboulsi et al. (2023)	Visão geral das arquiteturas de RNC propondo soluções para imagens de segmentação cardíaca.
Análise da utilização de AP em imagens de SPECT cardíacos	Apostolopoulos et al. (2023)	Aborda principais objetivos e recentes descobertas nos modelos de AP em imagens cardíacas de SPECT.

artefatos, ajustando hiperparâmetros, iii) validar o desempenho do modelo por meio de métricas quantitativas, como o coeficiente de Dice (D_c), e análise qualitativa por especialistas, iv) comparar as segmentações automatizadas com as manuais para determinar a viabilidade clínica do modelo e v) avaliar a aplicabilidade prática do modelo no contexto hospitalar, considerando impacto na redução de tempo e na qualidade da imagens utilizadas para análise de exames.

Além da relevância científica e clínica, esta pesquisa apresenta viabilidade econômica, uma vez que se baseia em sistema computacional desenvolvido somente pela equipe do projeto. Para melhor organização, este trabalho está estruturado da forma: inicialmente, o Capítulo 2 e Capítulo 3 oferecem as bases teóricas e os conceitos necessários para a compreensão da abordagem metodológica, discutindo brevemente a doença cardíaca e a aplicação dos sistemas computacionais. Em seguida, o Capítulo 4 descreve minuciosamente o método empregado, ilustrando o processo completo do exame, desde sua execução até a avaliação realizada pelo especialista. O Capítulo 5,

apresenta os achados resultantes da aplicação do método proposto, além da discussão sobre os resultados e implicações. Por fim, as reflexões finais e as contribuições do estudo são sintetizadas no Capítulo 6, conclusão.

CAPÍTULO 2

ENFERMIDADE CARDÍACA

Esta seção apresenta os fundamentos relacionados à DAC, com destaque para os aspectos clínicos e fisiopatológicos que justificam sua relevância como problema de saúde pública. Em seguida, discutem-se os desafios técnicos associados à presença de artefatos em exames de imagem, os quais podem comprometer a precisão diagnóstica e motivam a busca por soluções computacionais para reduzir seus efeitos. Na sequência, descreve-se a CPM, exame amplamente empregado na avaliação funcional do coração e diretamente impactado por estas distorções.

2.1 Panorama clínico da doença arterial coronariana

A DAC é uma condição cardiovascular prevalente e potencialmente letal, caracterizada por resposta inflamatória crônica que culmina na formação de placas arterioscleróticas nas artérias coronárias (SHAHJEHAN; BHUTTA, 2022). Estas placas, constituídas por depósitos lipídicos, podem sofrer calcificação progressiva e provocar estreitamento significativo dos vasos, resultando em estenose e comprometimento do fluxo sanguíneo ao miocárdio (NEUFELD et al., 2021). A redução do suprimento sanguíneo pode desencadear sintomas como dor torácica transitória e angina (SHAHJEHAN; BHUTTA, 2022), além de manifestações como desconforto retroesternal, sensação de peso ou pressão no tórax, frequentemente irradiando para mandíbula, ombros, dorso ou membros superiores (MALAKAR et al., 2019).

A angina, um dos sintomas característicos da DAC, pode ocorrer mesmo em repouso, sugerindo obstrução crítica das artérias coronárias, geralmente superior a 90% (MALAKAR et al., 2019; SHAHJEHAN; BHUTTA, 2022). A apresentação clínica da DAC pode ser aguda ou crônica, incluindo, respectivamente, a angina instável e o infarto agudo do miocárdio, bem como a angina pectoris em sua forma crônica. Em estágios avançados, a doença pode evoluir para insuficiência cardíaca e, em alguns casos, resultar em óbito (NEUFELD et al., 2021). Há situações em que a manifestação é súbita e fatal, o que reforça a relevância da identificação precoce dos fatores de risco, visando à redução de eventos inesperados (HANSON et al., 2013).

A doença cardiovascular (DCV) decorre de uma interação complexa entre fatores genéticos e ambientais. A adoção de estratégias preventivas e terapias específicas contribui significativamente para a melhora do prognóstico em pacientes com DAC (MA-

LAKAR et al., 2019). Enquanto fármacos atuam diretamente nos mecanismos fisiopatológicos da doença, intervenções invasivas visam restabelecer o fluxo sanguíneo em casos de obstruções severas (NEUFELD et al., 2021). Embora a angiografia coronariana por cateterismo continue sendo o método de referência para o diagnóstico da DAC, exames como ecocardiografia, ressonância magnética cardíaca e CPM têm se destacado como alternativas relevantes na investigação e no manejo clínico (HANSON et al., 2013).

2.2 Aplicação e desempenho da cintilografia de perfusão miocárdica

A cintilografia de perfusão do miocárdio (CPM) é o exame de imagem amplamente utilizado para o diagnóstico, estratificação de risco e prognóstico da DAC. É ferramenta de detecção de estenoses nas artérias coronárias, incluindo a identificação de isquemias e infartos do miocárdio, através da avaliação qualitativa e semiquantitativa de padrões de perfusão regional (ORA; GAMBHIR, 2019; NOLAN et al., 2021). As indicações para a realização da CPM são determinadas pelo contexto clínico e pela suspeita de defeitos na perfusão ou pela necessidade de avaliar a resposta após a intervenção. Isto compreende de situações como a detecção de DAC após evidências, como: i) elevação de troponina, ii) síncope com risco intermediário de DAC, iii) nova ou piora de angina em pacientes diagnosticados, iv) avaliação do risco de isquemia após revascularização e v) determinação da viabilidade miocárdica em pacientes candidatos à revascularização (PATEL; ALZHRANI, 2019).

Para a realização do exame, é essencial que os pacientes vistam roupas confortáveis e removam quaisquer objetos metálicos que possam interferir na imagem. Além disto, é necessária a suspensão de medicamentos e alimentos contendo substâncias como metilxantinas e cafeína nas 24 horas que antecedem o procedimento (FATHALA, 2011). Embora haja diversas opções de radiofármacos disponíveis, aqueles que utilizam tecnécio ^{99m}Tc são preferidos devido à menor exposição à radiação em comparação com o tálio-201 (^{201}Tl), além da produção de imagens de qualidade superior e menor custo. O composto catiônico tetrafluorborato tetramibi cuproso, comercialmente vendido como MIBI ou sestamibi, quando marcado com ^{99m}Tc , se acumula nos tecidos viáveis do miocárdio (NOLAN et al., 2021; HYAFIL et al., 2019). Após a administração intravenosa do sestamibi marcado com ^{99m}Tc , o radiofármaco é retirado da corrente sanguínea e, por meio de difusão passiva, é retido dentro das células. Esta absorção do traçador espelha a perfusão do ventrículo esquerdo, em conformidade com o fluxo sanguíneo no tecido viável (STROK et al., 2023).

Desta forma, observam-se variações na distribuição sanguínea durante as fases de repouso, que representa a condição basal, e de esforço, na qual o músculo cardíaco requer maior oxigenação. Isto indica a perfusão comprometida em caso de obstrução nos vasos (LI; KRONENBERG, 2021). Além do miocárdio, o material radioativo se acumula em outros órgãos e tecidos. A biodistribuição fisiológica abarca glândulas salivares, tireoide, fígado, vesícula biliar, intestino delgado e grosso, rins, bexiga, plexo coroide e músculo esquelético. A principal via de excreção do sestamibi marcado com ^{99m}Tc é hepatobiliar, seguida por eliminação em menor quantidade via urinária (ATHAR; HELLER, 2008). Embora existam múltiplos protocolos validados, os procedimentos da CPM geralmente envolvem duas etapas a serem comparadas: repouso e esforço. Seguindo os protocolos de um dia, a atividade administrada para a etapa de repouso varia entre $2,5 \text{ MBq/kg}$ a $3,5 \text{ MBq/kg}$, enquanto para a etapa de esforço é de $7,5 \text{ MBq/kg}$ a 10 MBq/kg , representando diferença de aproximadamente três vezes (LI; KRONENBERG, 2021).

As projeções do miocárdio visualizadas no exame são observadas na Figura 2.1. Embora o estudo apresentado na Figura 2.2 seja considerado normal, atenuações e artefatos podem ocorrer nas paredes do ventrículo falseando um comprometimento das artérias que irrigam o miocárdio. Padroniza-se os segmentos apical, septal, anterior e anteroseptal irrigados pela artéria descendente anterior, segmentos inferior e inferosseptal correspondente a coronária direita e anterolaterais e inferolaterais à artéria circunflexa (HIRONAKA et al., 2017).

As aquisições de imagem adquiridas por meio da técnica de single photon emission tomography (SPECT), como ilustrado na Figura 2.2, iniciam-se pela injeção endovenosa do ^{99m}Tc -MIBI, seguida da ingestão de dieta rica em gordura e/ou água gelada para estimular a excreção hepática e o peristaltismo (HYAFIL et al., 2019). Após esta fase, inicia-se a aquisição das imagens de repouso. O paciente é posicionado em decúbito dorsal (supine) ou ventral (prone), com os braços elevados acima da cabeça para evitar atenuação ocasionada pela sobreposição do braço esquerdo na imagem cardíaca (NOLAN et al., 2021). Posteriormente à fase de repouso, dependendo da condição do paciente, a etapa de estresse é iniciada (PATEL; ALZHRANI, 2019).

Nova administração do traçador é realizada quando o paciente atinge o pico da frequência cardíaca na esteira/bicicleta ou no sexto minuto da infusão do fármaco que induzirá o estresse farmacológico (NOLAN et al., 2021; PATEL; ALZHRANI, 2019). A aquisição da imagem correspondente a esta etapa é realizada entre 15 a 45 minutos




Figura 2.1 - Projeções do miocárdio visualizadas no exame: eixo curto, eixo longo horizontal e eixo longo vertical.




Figura 2.2 - Aquisição em SPECT do exame de Cintilografia de Perfusão do Miocárdio. O estudo revela concentração homogênea do indicador no miocárdio durante as etapas de esforço e repouso, indicando a ausência de elementos sugestivos de isquemia regional nos cortes tomográficos estudados.

após a recuperação do estresse (PATEL; ALZHRANI, 2019). Geralmente, a etapa de esforço é sincronizada com o eletrocardiograma ao SPECT para avaliar simultaneamente a perfusão e a função cardíaca (FATHALA, 2011). Exercício físico em esteira ergométrica é a preferência, pois oferece informações prognósticas valiosas. No en-

tanto, pacientes incapazes de realizar atividades físicas ou aqueles com bloqueio de ramo esquerdo ou estimulação ventricular, são submetidos ao aumento da frequência cardíaca por indução farmacológica, comumente com o vasodilatador Dipyridamol. Porém, pacientes com contraindicações para vasodilatadores são submetidos à etapa de esforço com dobutamina, visto que o mecanismo de ação para o aumento do fluxo sanguíneo é diferente (LI; KRONENBERG, 2021; MANN; WILLIAMS, 2020).

A análise das imagens permite observar o mecanismo fisiológico em que as arteríolas miocárdicas distais mantêm o fluxo de sangue normal do indivíduo em repouso. No entanto, em condições de estresse, com o aumento do consumo de oxigênio, há vasodilatação significativa da vascularização normal, mas pouca nos vasos distais estenosados, o que aparece nas imagens como defeitos de captação do material radioativo (LI; KRONENBERG, 2021). Exames com miocárdio isquêmico geralmente aparecem normais na etapa de repouso e com menor captação do radiotraçador no esforço, enquanto o defeito persistente nas duas etapas indica infarto devido à fibrose presente (NOLAN et al., 2021). A CPM é considerada normal quando a concentração do traçador é homogênea nas duas etapas (ALVARENGA; SMANIO, 2021).

Novos equipamentos dedicados a imagens cardíacas, com detectores de telureto de cádmio e zinco (CZT), permitem a conversão direta dos fótons gama em sinal elétrico e algoritmos de reconstrução iterativa diferenciada, resultando em maior sensibilidade, alta resolução espacial e energética quando comparados às câmeras gama convencionais. Isto permite a redução do tempo de exame, exposição à radiação e, conseqüentemente, mais conforto e segurança para o paciente (AGOSTINI et al., 2016; BUDZYŃSKA et al., 2019; CANTONI et al., 2021). Apesar das vantagens, as câmeras CZT têm limitações, como a ausência de correção do movimento e de atenuação integrada, estratégia utilizada para reduzir ou eliminar artefatos (AGOSTINI et al., 2016).

2.3 Desafios técnicos na cintilografia de perfusão miocárdica

A qualidade das imagens obtidas por CPM pode ser comprometida pela presença de artefatos, os quais representam um dos principais desafios na interpretação precisa dos exames cardíacos (RAMOS et al., 2020). Na medicina nuclear, artefatos correspondem a anomalias visuais nas imagens que distorcem os processos fisiológicos ou fazem com que estruturas anatômicas normais aparentem ser patológicas. Estas distorções reduzem a qualidade do exame, podendo induzir a interpretações equi-

vocadas e à indicação de procedimentos invasivos e onerosos (NOLAN et al., 2021; DITTRICH; CHOWDHURY, 2021).

Equipamentos com CZT são particularmente sensíveis a artefatos relacionados ao posicionamento do paciente, como o artefato em formato de banana, por vezes observado nos mapas polares, como ilustrado na Figura 2.3, adaptada de Fiechter et al. (FIECHTER et al., 2012). Este artefato está relacionado ao posicionamento do coração fora do centro do campo de visão, e aparece, com frequência, em pacientes com obesidade que são mais difíceis de centralizar, no entanto, ao reposicionar o coração no campo de visão do equipamento, este efeito pode ser eliminado da imagem (BUDZYŃSKA et al., 2019). Para minimizar estes efeitos, é necessário que o paciente seja cuidadosamente monitorado durante a aquisição das imagens, e que esteja completamente relaxado, orientado e posicionado antes do início do exame (SALKICA et al., 2020).

Outros artefatos relevantes estão relacionados à atenuação dos tecidos mamário e diafragmático, com impacto direto sobre as paredes do miocárdio. A atenuação diafragmática, mais comum em homens, afeta principalmente a parede inferior do ventrículo esquerdo (VE). A atenuação mamária, observada com maior frequência em mulheres, pode comprometer as paredes anterior, anterosseptal ou lateral, sendo sua extensão influenciada pela densidade, volume e posição da mama em relação ao VE (MITITELU et al., 2021; HEINLE; SIRAJ, 2009).

Estes artefatos, apesar de comuns, podem manifestar-se de duas formas principais: i) como redução da captação na parede miocárdica, sugerindo falsamente isquemia ou ii) como captação aumentada que mascara eventuais defeitos verdadeiros, especialmente na parede inferior. Estratégias para reduzir estes efeitos incluem a realização do exame em decúbito ventral (prone) ou a aquisição complementar de imagens por tomografia computadorizada, que permite correção por atenuação (MITITELU et al., 2021; HEINLE; SIRAJ, 2009).

A análise quantitativa combinada de imagens adquiridas em decúbito dorsal (supine) e ventral (prone) tem se apresentado especialmente útil em mulheres, elevando as taxas de normalidade e a especificidade dos exames sem prejuízo à sensibilidade na detecção da DAC. Este resultado decorre da menor interferência dos tecidos moles no posicionamento em prone (RAMOS et al., 2020). Durante a etapa de estresse farmacológico, a via de excreção do radiofármaco e a dilatação dos vasos esplênicos




Figura 2.3 - Artefato em forma de banana relacionado ao posicionamento do paciente influenciando no (A) eixo curto do ventrículo esquerdo com hiper captação em região septal e (B) segmentos do mapa polar.

contribuem para o aumento da atividade extracardiaca, especialmente em órgãos abdominais como estômago, intestinos e fígado, o que pode comprometer a visualização do ventrículo esquerdo (STROK et al., 2023). Como estratégias para mitigar esta captação excessiva, incentiva-se caminhadas para estimular o movimento peristáltico, além do consumo de líquidos e alimentos ricos em gordura, ou aumentar o intervalo de tempo de aquisição da imagem (STROK et al., 2023).

Outros fatores que comprometem a qualidade do exame estão associados à preparação, manipulação e armazenamento do radiofármaco. A legislação vigente exige que a eficiência de marcação do tecnécio-99mTc-MIBI seja superior a 95%, pois concentrações inadequadas podem levar ao acúmulo de pertecnetato livre ou de formas coloidais em glândulas salivares, tireoide, estômago, fígado e intestinos (ATHAR; HELLER, 2008; HEINLE; SIRAJ, 2009). Diante destas variáveis, torna-se necessário compreender os fatores que podem gerar artefatos e interferências, bem como adotar medidas para corrigi-los, de modo a assegurar maior precisão diagnóstica na CPM.

2.4 Considerações finais

Este capítulo foi escrito para expor conceitos fundamentais da doença arterial coronariana, diagnosticada por meio do exame de CPM e artefatos que podem interferir na imagem, componente principal de estudo e detecção deste trabalho por meio da implementação de modelo computacional. O processo de implementação e aplicação

do modelo a ser utilizado será apresentado no próximo capítulo.

CAPÍTULO 3

APLICAÇÃO DE SISTEMAS COMPUTACIONAIS

Neste capítulo, são introduzidos os conceitos fundamentais relacionados à implantação de sistemas computacionais em ambientes hospitalares, inteligência artificial, construção de arquiteturas de redes neurais convolucionais e modelos de redes neurais artificiais empregados na análise automatizada de imagens médicas.

3.1 Infraestrutura computacional e integração da inteligência artificial em imagens médicas

A implantação de sistemas computacionais em ambientes hospitalares, voltados ao tratamento, armazenamento, gerenciamento e distribuição de exames médicos, constitui processo indispensável à modernização e à otimização da gestão de informações clínicas (DAHER; HAJJDIAB, 2018; DOUKAS et al., 2010). Denominado Picture Archiving and Communication System (PACS), este sistema representa a tecnologia de referência na área da saúde para a manipulação de imagens, como radiografias, tomografias e ressonâncias magnéticas (BECKER; ARENSON, 1994; BERNABE et al., 2019). Ao substituir os tradicionais filmes radiológicos por imagens digitais, o PACS proporciona acesso ágil e seguro aos dados, além de favorecer a comunicação entre departamentos e especialidades, promovendo ganhos expressivos na eficiência diagnóstica e terapêutica (TANG et al., 1999; WANG et al., 2010).

As imagens médicas são, em geral, armazenadas no formato *Digital Imaging and Communications in Medicine* (DICOM), padrão internacional amplamente adotado em decorrência da crescente digitalização dos serviços de saúde (LAROBINA; MURINO, 2014; CHATTERJEE et al., 2017). Contudo, a diversidade de sintaxes existentes no padrão DICOM pode dificultar a integração entre sistemas heterogêneos. Para reduzir este problema, o *Vendor Neutral Archive* (VNA) realiza a desagregação dos dados oriundos do PACS antes da migração para o novo repositório, assegurando a correta interpretação das sintaxes e facilitando a interoperabilidade entre os sistemas (SIOCHI et al., 2021; ACT, 1996). O VNA atua como interface entre os diversos formatos de imagem e o PACS, utilizando algoritmos para interpretar os dados e executar a normalização. Em adicional, o sistema ajusta as etiquetas (*tags*) associadas ao DICOM, aprimorando a compatibilidade entre plataformas (PANTANOWITZ et al., 2018; ZHANG et al., 2023).

No contexto do VNA, a preservação da privacidade é necessária, pois abarca ampla gama de informações médicas e imagens provenientes de diversas fontes. Para garantir a segurança e controle de acesso, é importante que o VNA adote medidas como protocolos de criptografia e autenticação de usuários, juntamente com políticas de privacidade rigorosas, assegurando que apenas profissionais da saúde autorizados tenham acesso aos dados dos pacientes (BERNABE et al., 2019). Além disto, é necessário que o VNA esteja em total conformidade com regulamentações de proteção de dados, como o *Health Insurance Portability and Accountability Act* (HIPAA), e outras leis de privacidade de saúde em jurisdições correspondentes (ACT, 1996). Ao adotar estas medidas, o VNA garante a preservação da integridade e confidencialidade das informações dos pacientes.

Adicionalmente, o anonimizador aparece como ferramenta importante para manter a privacidade e confidencialidade dos pacientes durante o processo de desidentificação de dados médicos. Este componente remove ou substitui informações pessoais identificáveis, como nomes, números de identificação e datas de nascimento, por códigos ou dados fictícios (CHATTERJEE et al., 2017). Este procedimento permite que os registros médicos sejam utilizados para pesquisa, treinamento ou análise estatística sem comprometer a identidade dos pacientes. Isto fortalece a segurança e integridade do VNA, garantindo que informações sensíveis permaneçam protegidas enquanto contribuem para o avanço tecnológico na área de saúde (ZHANG et al., 2023).

Outra ferramenta necessária para a implantação de sistema computacional é o serviço de armazenamento de dados, solução tecnológica voltada para a gestão e preservação de informações críticas relacionadas aos exames clínicos dos pacientes. Exemplo deste tipo de recurso é o *Amazon Simple Storage Service* (Amazon S3), oferecido pela *Amazon Web Services* (AWS) (WANG et al., 2010). Este serviço provê infraestrutura altamente segura e escalável para o armazenamento confiável e acessível de dados, independentemente da localização (DAHER; HAJJDIAB, 2018). No contexto hospitalar, isto significa que as imagens médicas podem ser armazenadas de maneira eficiente e organizada, juntamente com os dados correlacionados, como informações do paciente e datas de exame. Adicionalmente, o serviço incorpora robustos mecanismos de segurança e adere a regulamentações de proteção de dados, assegurando a confidencialidade e a integridade das informações médicas (DOUKAS et al., 2010).

Com a consolidação de ambientes computacionais estruturados e interoperáveis,

torna-se possível incorporar ferramentas analíticas mais avançadas, como os modelos de IA.

3.2 Inteligência Artificial

A disseminação da IA tem sido impulsionada por avanços técnicos expressivos, como o aumento do poder computacional, a ampliação da capacidade de armazenamento de dados e a obtenção de resultados experimentais promissores. Este progresso é particularmente perceptível em áreas voltadas à tomada de decisão, como a análise de imagens médicas e operações realizadas por meio da internet ([BARRAGÁN-MONTERO et al., 2021](#); [HAH](#); [GOLDIN, 2021](#)). Atualmente, a internet constitui o principal canal para o tráfego de dados, com parte significativa dos sistemas computacionais operando de forma conectada, o que apresenta a crescente integração da IA no cotidiano. Neste contexto, a convergência entre softwares, conectividade em rede e algoritmos inteligentes tem favorecido a implementação de sistemas computacionais avançados em ambientes clínicos e de pesquisa.

Com a infraestrutura computacional devidamente estabelecida, torna-se viável empregar modelos de IA em suporte a tarefas clínicas especializadas. Entre as tecnologias disponíveis, destaca-se a CNN, concebida para processar dados organizados em estrutura matricial, como imagens médicas ([WOŹNIAK et al., 2023](#)). Estas redes são capazes de identificar padrões complexos por meio de camadas convolucionais que aplicam filtros sobre diferentes regiões da imagem ([MARQUES et al., 2020](#)). Um exemplo amplamente adotado é a arquitetura U-Net, desenvolvida para segmentação de imagens médicas, composta por duas etapas: contração, responsável pela extração de características, e expansão, voltada à reconstrução da segmentação ([RONNEBERGER et al., 2015](#)). Apesar de sua eficiência, a U-Net pode apresentar limitações em contextos com conjuntos de dados reduzidos, heterogêneos ou desbalanceados.

Como desdobramento da arquitetura U-Net, a nnU-Net incorpora aprimoramentos relevantes, incluindo o uso de modelos pré-treinados, a configuração automática de hiperparâmetros e a adoção de estratégias de validação mais resilientes ([DU et al., 2020](#); [ISENSEE et al., 2021a](#)). Suas abordagens específicas de treinamento e adaptação estrutural permitem ajustar a arquitetura às particularidades dos conjuntos de dados, otimizando as etapas de pré e pós-processamento ([ISENSEE et al., 2021b](#); [VERDIER et al., 2023](#)). A capacidade de operar eficientemente com bases de dados médicas restritas torna a nnU-Net especialmente indicada para segmentações precisas,

contribuindo para diagnósticos mais confiáveis e condutas terapêuticas melhor fundamentadas (ISENSEE et al., 2021b). A Figura 3.1 ilustra a estrutura da arquitetura clássica da nnU-Net.

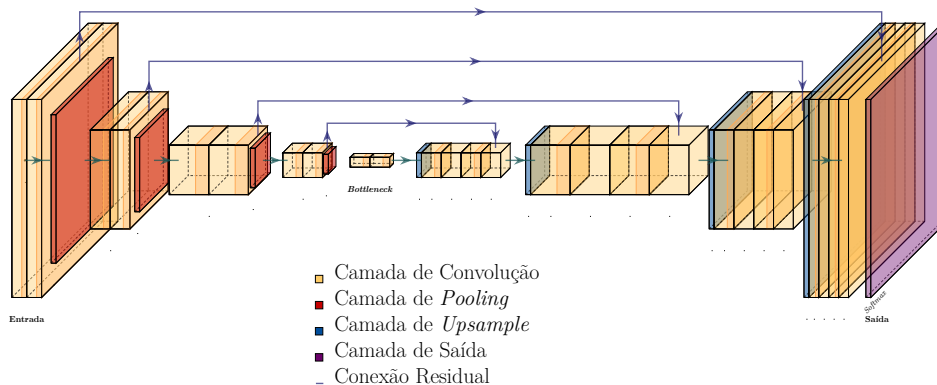


Figura 3.1 - Arquitetura clássica da rede nnU-net.

A Figura 3.1 ilustra a estrutura simétrica composta por etapas de codificação e decodificação, conectadas por caminhos de atalho que preservam as informações espaciais (ISENSEE et al., 2021b). Ao ser implementada em novo conjunto de dados, a nnU-Net exige apenas ajustes mínimos, com base em heurísticas, o que reduz significativamente o custo computacional e permite a utilização do treinamento padrão da arquitetura (SIDDIQUE et al., 2021).

3.3 Funcionamento da nnU-Net

O que diferencia a nnU-net são suas estratégias de treinamento e arquitetônicas exclusivas (ISENSEE et al., 2021b). Ela utiliza método de treinamento eficiente, adaptando automaticamente as estratégias de pré-processamento e pós-processamento, bem como adapta a morfologia do modelo para aprimorar a precisão da segmentação (ISENSEE et al., 2021b; VERDIER et al., 2023). Além disto, a nnU-net é ajustada para lidar com conjuntos de dados médicos frequentemente restritos em tamanho, ocorrência comum em tarefas de segmentação médica. Isto a torna especial para aplicações que demandam segmentações precisas em imagens médicas, contribuindo para diagnósticos mais precisos e tratamentos mais eficientes (ISENSEE et al., 2021b).

Ao implementar a nnU-Net em novo conjunto de dados, são realizadas poucas alterações empíricas, o que diminui o custo computacional e restringe o processo ao

treinamento padrão da rede. A configuração automatizada da nnU-Net inicia com a análise das características específicas do conjunto de dados, seguida pela aplicação de regras heurísticas. Por padrão, são geradas três configurações distintas de U-Net pela nnU-Net: i) U-Net 2D; ii) U-Net 3D, que opera na resolução completa da imagem e iii) cascata U-Net 3D. A primeira U-Net processa imagens em resolução reduzida, enquanto a segunda é treinada para aprimorar os mapas de segmentação produzidos pela primeira em resolução máxima.

Após a realização de validação cruzada, a nnU-Net seleciona, com base em critérios empíricos, a configuração ou o conjunto que apresentou o melhor desempenho. Por fim, a nnU-Net decide, empiricamente, eliminar componentes menores no pós-processamento, caso isto resulte em melhorias no desempenho. O resultado deste processo automatizado de configuração e treinamento é a obtenção de modelos completamente treinados, prontos para realizar previsões em novas imagens, conforme descrito por (ISENSEE et al., 2021b) e (SIDDIQUE et al., 2021)

3.4 Considerações finais

Este capítulo introduziu o conceito de implantação de modelos computacionais e as ferramentas requeridas para a aplicação da RNC. Adicionalmente, ofereceu descrição concisa do funcionamento da arquitetura da rede neural convolucional selecionada para a identificação de artefatos em cintilografia miocárdica. O capítulo seguinte detalhará a metodologia proposta para o mapeamento e identificação de artefatos, empregando técnicas de inteligência artificial.

CAPÍTULO 4

METODOLOGIA

Neste capítulo, apresenta-se a metodologia proposta para este trabalho, incluindo uma contextualização detalhada. Descreve-se o protocolo para a realização do exame de cintilografia de perfusão miocárdica, bem como as estratégias de gestão dos dados e o modelo de predição utilizado. Ao final do capítulo, define-se o processo de validação do sistema proposto.

4.1 Contextualização

O objetivo deste trabalho é mapear o processo de identificação do ventrículo esquerdo na primeira fase do projeto, seguido da identificação dos artefatos em cintilografia miocárdica por meio da aplicação de inteligência artificial em uma segunda fase. A fase I compreende desde o desenvolvimento do modelo computacional até segmentação do ventrículo esquerdo, enquanto a fase II engloba a segmentação e análise dos artefatos. O estudo abarca desde o preparo do paciente até a condução do exame de cintilografia de perfusão miocárdica, explorando a utilização de IA para aprimorar a qualidade das imagens obtidas. Adicionalmente, propõe-se o desenvolvimento e a otimização dos hiperparâmetros da rede neural artificial convolucional, com a validação dos resultados por meio da avaliação de especialistas. Este trabalho visa auxiliar equipe técnica durante a realização do exame, e conseqüentemente melhorar qualidade da imagem, diagnóstico e tratamento da doença arterial coronariana. A metodologia adotada inclui a coleta de dados em ambiente clínico, a preparação e análise destes dados usando a Plataforma 3D *Slicer* para segmentação manual e, em seguida, a aplicação de modelos de IA para segmentação automatizada, concentrando na precisão da identificação final dos artefatos.

O procedimento se inicia com a realização do exame do miocárdio, nas quais as imagens são adquiridas por meio do equipamento *Discovery NM 530c*, da *General Electric Company Healthcare Ltd.* Trata-se de gama câmara *multipinhole*¹ com dezenove detectores semicondutores de Cádmiio, Zinco e Telúrio (CZT), organizados em matriz de 32×32 [px] dispostos em arco, de forma que todos os *pinholes* estejam direcionados para focalizar o coração. O processo é concluído quando os exames

¹Dispositivo de imagem usado em medicina nuclear que utiliza múltiplos orifícios para captar projeções de radiação gama, aumentando a resolução e a sensibilidade em exames como a tomografia por emissão de fóton único (SPECT).

originais são comparados por especialistas com os exames segmentados pela IA. O fluxo completo da metodologia proposta é ilustrado na Figura 4.1.

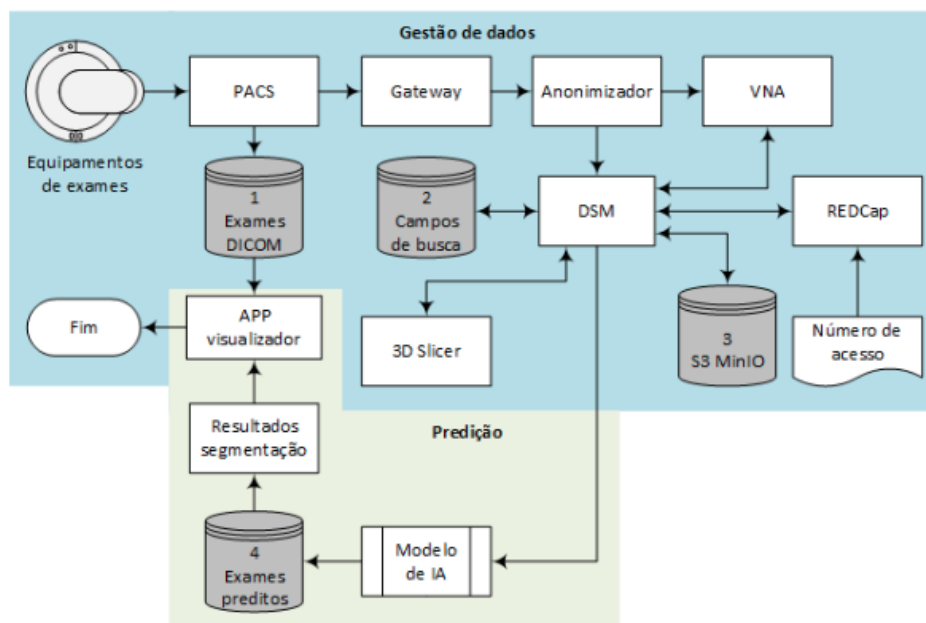


Figura 4.1 - Fluxograma da metodologia proposta da Fase I.

Após identificação do VE surante primeira etapa do projeto, seguimos para segunda fase com a coleta e segmentação manual dos dados até a validação dos resultados obtidos por meio do modelo de IA dos artefatos.

4.2 Protocolo para realização do exame

Este estudo possui caráter prospectivo e inclui todos os pacientes encaminhados para a realização do exame de CPM, independentemente de apresentarem ou não histórico de doença coronariana. Todos os participantes voluntariamente assinaram o Termo de Consentimento Livre e Esclarecido (TCLE), concordando em ceder as imagens do exame após sua conclusão e elaboração do laudo. Desta forma, a pesquisa é conduzida em conformidade com os requisitos do comitê de ética, e o desenvolvimento do projeto se inicia após a anonimização dos dados do paciente. Neste processo, os pesquisadores envolvidos na análise não têm acesso a informações sobre o histórico médico do paciente, restando apenas os dados essenciais para a condução da pesquisa.

Conforme as diretrizes de orientação para o exame, a CPM é realizada com o paciente em posição de decúbito dorsal, seguindo o protocolo de um dia. O procedimento começa com a administração do radiofármaco ^{99m}Tc -MIBI, a dosagem é ajustada de acordo com o peso do paciente. Após uma hora, as imagens em repouso são adquiridas utilizando o equipamento *Discovery NM 530c*. O tempo de aquisição é de seis minutos, com janela de energia de 20%, fotopico de 140 [keV], tamanho de pixel de 2.46×2.46 [mm] matriz de 32×32 [px], fator multiplicador $zoom = 1$, e posteriormente as imagens são reconstruídas utilizando o *Software Myovation for Alcyone*[®] da *General Electric Company Healthcare Ltd*. Este software emprega o algoritmo de reconstrução iterativa *Maximum Likelihood-Expectation Maximization* (MLEM) ([General Electric Company Healthcare Ltd, 2017](#)).

4.3 Gestão dos dados

As imagens, após serem reconstruídas pelo *Software Myovation for Alcyone*[®], são digitalmente encaminhadas para o PACS, onde uma cópia de cada exame é armazenada no **banco de dados 1** no formato DICOM. Posteriormente, os exames são transferidos para o *Gateway*, módulo que possibilita a transmissão segura de imagens em padrões DICOM e não DICOM entre diferentes equipamentos, hospitais e clínicas, realizando uso de protocolos e padrões de interoperabilidade FHIR² e DICOM.

Para assegurar a confidencialidade das informações sensíveis dos pacientes e controlar os dados essenciais para a formação do banco de imagens, é necessário realizar a anonimização dos exames. Isto implica na remoção de qualquer informação de identificação dos pacientes. Para realizar este processo, é utilizado o anonimizador com base no *Clinical Trials Processor (CTP) DICOM Pixel Anonymizer*³, ferramenta projetada para manipular imagens médicas no formato DICOM ([FREYMANN et al., 2012](#)). O *DICOM Pixel Anonymizer* utiliza arquivo de *script* para determinar quais partes da imagem devem ser removidas com base em informações que não estão contidas nos pixels do arquivo DICOM. O processo consiste na análise dos objetos DICOM recebidos. O *DICOM Pixel Anonymizer* verifica se o objeto trata-se de ima-

²Fast Healthcare Interoperability Resources é o padrão de interoperabilidade em saúde projetado para facilitar a troca de informações entre diversos sistemas e aplicações. Este padrão foi desenvolvido pela HL7 International, organização de padronização no campo da saúde. A abordagem tem base na Web e simplifica a integração de sistemas de saúde e assegura a uniformidade na troca de dados e imagens médicas ([BRAUNSTEIN, 2018](#); [AYAZ et al., 2021](#)).

³DICOM Pixel Anonymizer: <https://github.com/susom/mirc-ctp>

gem, e se for o caso, ele verifica se a imagem está descompactada ou possui alguma compressão específica. Se os critérios forem atendidos, o anonimizador segue o *script* para remover as partes designadas da imagem. Caso contrário, o objeto é repassado sem modificações. As regiões a serem removidas são definidas por coordenadas em dimensões retangulares.

Desta forma, os pesquisadores não possuem acesso à identidade do paciente associado ao exame em análise. No entanto, ao término do processo, o especialista precisa comparar o exame obtido pelo equipamento com a versão segmentada pela IA. Para este fim, é elaborado o formulário utilizando a plataforma *Web Research Electronic Data Capture* (REDCap) para coleta e gerenciamento de dados (HARRIS et al., 2009; HARRIS et al., 2019). Neste formulário estão registrados os números de acesso que identificam os exames anonimizados, estabelecendo a ligação com os exames armazenados no **banco de dados 1**. Apenas o médico especialista associado ao paciente possui permissão para aceder o número de acesso no REDCap.

O exame anonimizado é encaminhado para o VNA, que neste caso é o sistema dedicado ao armazenamento, centralização e gestão das imagens médicas. O VNA proporciona administração eficiente e segura dos dados anonimizados. Tanto o processo de anonimização quanto o VNA direcionam os dados para o gerenciador de conjunto de dados (DsM). Este facilita a organização, manipulação e análise de dados, oferecendo funcionalidades para importação, transformação, limpeza e exploração dos dados, otimizando o processo de manipulação, especialmente em contextos de grandes volumes de dados. O DsM está conectado tanto ao **banco de dados 2** quanto ao **banco de dados 3**. O **banco de dados 2** tem a função de armazenar os campos de busca, os quais são necessários para a execução da pesquisa e permanecem inalterados durante o processo de anonimização. Estes campos abarcam informações como sexo e idade dos pacientes, além de outros dados relevantes.

O **banco de dados 3** corresponde ao S3 MinIO, Simple Storage Service (Amazon S3) e sua função é armazenar todos os dados que foram processados no DsM. A Plataforma 3D *Slicer* é então empregada para a visualização, processamento, análise e segmentação manual⁴ das imagens médicas. A seleção desta plataforma é respaldada na extensa variedade de ferramentas disponíveis para segmentação de

⁴Processo em que o operador humano, geralmente um profissional de saúde ou pesquisador, examina a imagem e utiliza software especializado para delinear manualmente as regiões de interesse (KHASAWNEH et al., 2022).

estruturas anatômicas, registro de imagens, geração de modelos 3D, medições quantitativas, entre outras funcionalidades (VELAZQUEZ et al., 2013; PINTER et al., 2012). Após as análises e a conclusão da segmentação, o conjunto de imagens segmentadas é transferido para o DsM.

4.4 Modelo de predição das paredes do ventrículo esquerdo: Fase I

Com o exame de imagem no formato DICOM disponível, previamente anonimizado, realiza-se a segmentação manual dos dados, passo necessário para o treinamento do modelo de IA. A geração das máscaras produzidas pelos especialistas, conhecidas como máscaras verdadeiras, é importante, pois o modelo de IA utilizado para a criação automática das máscaras é a nnU-Net⁵ (ISENSEE et al., 2021a). Esta técnica baseia-se em aprendizado supervisionado (GOODFELLOW et al., 2016). A segmentação manual é conduzida por meio da Plataforma *3DSlicer*, focalizando no ventrículo esquerdo durante a primeira etapa do projeto. A qualidade de cada máscara é verificada por especialistas distintos para assegurar a precisão. O passo final do processo de construção das máscaras de segmentação é o envio para o DsM juntamente com os respectivos exames em imagens.

Com os exames em imagem e as máscaras disponíveis no DsM, é possível realizar o treinamento do modelo nnU-Net. Para tanto, inicialmente é necessário nomear adequadamente os arquivos de imagem, suas máscaras correspondentes, e criar o arquivo *JavaScript Object Notation* (JSON)⁶. Neste trabalho, a função do arquivo JSON é descrever o conjunto de dados para que o fluxo de processamento da nnU-Net possa se adequar ao problema, detalhando características importantes do conjunto de dados, como modalidade de imagem, classes de segmentação e seus rótulos correspondentes. O processo de treinamento do modelo é conduzido em instância fornecida pela *Amazon Web Services* (AWS), integrada ao serviço de nuvem *Elastic Compute Cloud* (EC2), pertencente à família de instâncias G4, otimizada para cargas de trabalho gráficas e de computação de propósito geral. O treinamento da nnU-Net é dividido em quatro fases: i) criação das máscaras verdadeiras, ii) preparação dos dados, iii) treinamento do modelo, e iv) validação interna.

Com relação aos modelos disponíveis da nnU-Net, encontra-se três opções: i) UNet 2D, ii) U-Net 3D Fullres e iii) U-Net 3D *Cascade* (ISENSEE et al., 2021a). No

⁵Repositório nnU-Net: <https://github.com/MIC-DKFZ/nnUNet>.

⁶Formato leve para intercâmbio de dados, preferido na transmissão entre servidores e navegadores, sendo alternativa ao XML (BASSETT, 2015).

contexto deste estudo, a escolha é a U-Net 2D, considerando a natureza dos dados médicos em imagens fatiadas, os requisitos específicos para segmentação e a busca por equilíbrio ótimo entre resolução, precisão e eficiência computacional (FIRAT et al., 2022). A validação interna do modelo para o ventrículo é conduzida por meio da metodologia de validação cruzada *k-folds* (JAMES et al., 2013). Nesta abordagem, o conjunto de dados é particionado em k subconjuntos próprios (*folds*), sendo que o modelo é treinado e validado k vezes. A cada iteração, um dos subconjuntos próprios é designado para a validação, enquanto os demais são utilizados no treinamento. Este procedimento assegura a utilização de cada parte dos dados tanto para o treinamento quanto para a validação.

A nnU-Net automaticamente realiza a divisão dos dados em k -folds, gerando k -modelos distintos, cada um treinado ao longo de várias épocas. A otimização dos hiperparâmetros da nnU-Net é realizada através de técnicas de busca em grade, na qual diferentes conjuntos de hiperparâmetros são testados e avaliados no conjunto de validação, com o objetivo de encontrar a melhor combinação de hiperparâmetros que resulte no melhor desempenho do modelo utilizando a métrica de avaliação coeficiente de *Dice* D_c . Este processo é repetido iterativamente até encontrar a combinação ótima de hiperparâmetros.

Na validação interna, utiliza-se subconjunto próprio exclusivo de dados, diferente daquele empregado no treinamento, garantindo que o modelo não tenha sido previamente exposto a estes dados. A avaliação do desempenho utiliza o D_c , que compara as máscaras geradas pelo modelo de IA com as máscaras verdadeiras. Após o treinamento e validação do modelo, ele pode ser incorporado ao fluxo de processamento para gerar automaticamente máscaras de segmentação. Quando o exame em imagem é inserido no DB_3 por meio do **DsM**, o modelo de IA é ativado para criar a máscara de segmentação correspondente. Esta máscara é armazenada no DB_4 e torna-se acessível no **APP visualizador**. Esta funcionalidade permite que o médico especialista responsável pelo paciente compare o exame original com o exame contendo a máscara predita pelo modelo de IA.

4.5 Identificação dos artefatos: Fase II

Nesta seção é apresentada a descrição detalhada da metodologia da segunda fase do estudo, estruturada segundo o método hipotético-dedutivo. Parte-se da hipótese de que o uso de redes neurais convolucionais, em particular a arquitetura nnU-Net,

possibilita a identificação automática de artefatos em imagens de CPM, contribuindo para o aprimoramento da qualidade diagnóstica e para a racionalização do fluxo de trabalho clínico. Esta hipótese decorre da lacuna observada na literatura, a qual ainda carece de soluções automatizadas direcionadas especificamente à detecção de artefatos em CPM, os quais podem comprometer a acurácia dos exames e induzir a interpretações equivocadas. Com o objetivo de testar tal hipótese, delineia-se um conjunto de procedimentos empíricos que abrange desde a coleta e segmentação manual dos dados até a validação dos resultados obtidos por meio do modelo de IA.

A Figura 4.2 ilustra o fluxo metodológico proposto, estruturado em quatro etapas principais: i) aquisição, anonimização e gestão de dados clínicos, com uso integrado de ferramentas como PACS, VNA, REDCap⁷ e a plataforma 3D *Slicer*⁸, ii) segmentação manual do ventrículo esquerdo e dos artefatos, seguida da fusão das máscaras e da geração da classe sobreposta denominada artefato inviabilizante, iii) treinamento e otimização do modelo nnU-Net, com aplicação de algoritmo genético para definição de limiares de classificação a partir de mapas de probabilidade e iv) avaliação do modelo por meio de validação quantitativa, utilizando o D_c , e validação qualitativa cega realizada por especialistas. Este processo busca assegurar a aplicabilidade clínica do modelo, com enfoque em automação, auditabilidade e conformidade com os padrões de qualidade e segurança exigidos em ambientes hospitalares.

4.6 Aquisição e preparação dos dados clínicos

A Figura 4.2 ilustra o fluxo inicial de aquisição e organização dos exames de CPM utilizados neste estudo. Após a realização do exame clínico, as imagens são reconstruídas digitalmente e armazenadas no sistema PACS, conforme o padrão DICOM. Para assegurar a integridade do tráfego de dados entre sistemas heterogêneos, os arquivos são encaminhados ao VNA, o qual incorpora um módulo de comunicação compatível com múltiplos formatos, viabilizando a interoperabilidade entre equipamentos e ambientes hospitalares. Nesta etapa, adota-se o padrão FHIR⁹, que garante a padronização e a consistência dos registros durante a transferência entre disposi-

⁷Research Electronic Data Capture é a plataforma digital utilizada para coleta e gerenciamento seguro de dados em pesquisas científicas (HARRIS et al., 2009; HARRIS et al., 2019).

⁸Three-Dimensional Slicer é a plataforma de código aberto voltada à visualização, segmentação e análise quantitativa de imagens médicas, com ampla variedade de ferramentas especializadas (VELAZQUEZ et al., 2013; PINTER et al., 2012).

⁹Fast Healthcare Interoperability Resources é o padrão desenvolvido pela HL7 para padronizar a troca de dados e imagens médicas entre sistemas de saúde distintos (BRAUNSTEIN, 2018; AYAZ et al., 2021).

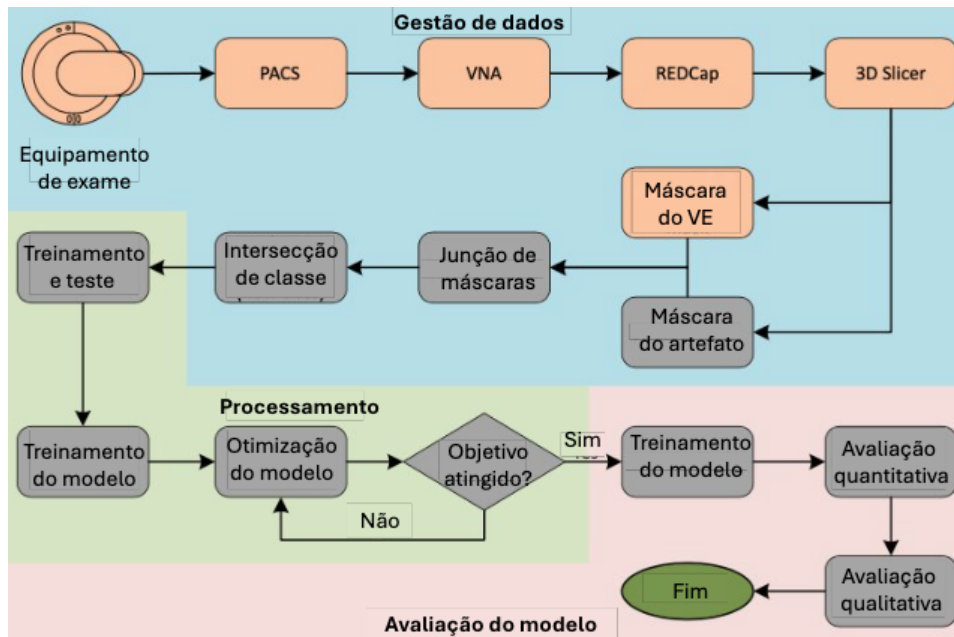


Figura 4.2 - Fluxograma da metodologia proposta da Fase II.

tivos. Antes de qualquer etapa analítica, os exames são submetidos a um processo de anonimização, o qual promove a remoção automatizada de identificadores sensíveis presentes nos cabeçalhos DICOM e, quando necessário, nas regiões visuais da imagem, por meio de *scripts* que definem áreas específicas para ocultação.

Após a anonimização, os exames são armazenados de forma estruturada em repositórios independentes, organizados segundo atributos clínicos e administrativos. Informações como idade e sexo, que não permitem a identificação dos pacientes, são preservadas para fins analíticos, enquanto os demais dados são protegidos por mecanismos de acesso restrito e controle de versionamento. Em seguida, os exames são transferidos para a plataforma *3D Slicer*, utilizada para a visualização e segmentação manual das estruturas de interesse. Esta etapa compreende a elaboração das máscaras iniciais que servirão de referência para o treinamento dos modelos supervisionados. Detalhamentos adicionais sobre este processo, incluindo as ferramentas empregadas e os critérios técnicos adotados, encontram-se em Nogueira *et al.* (NOGUEIRA *et al.*, 2025).

4.7 Desenvolvimento e validação do modelo supervisionado

De posse do exame de imagem no formato DICOM, previamente anonimizado, realiza-se a segmentação manual dos objetos de interesse nas imagens de CPM, etapa fundamental para o treinamento do modelo de IA, que opera segundo o paradigma de aprendizado supervisionado. A segmentação envolve três etapas sequenciais: i) delineamento do ventrículo esquerdo, ii) posteriormente, segmentação dos artefatos e iii) avaliação das máscaras geradas. Como medida de controle, o anotador não deve ter acesso à máscara do ventrículo durante a segmentação dos artefatos. A qualidade de cada máscara é avaliada por especialistas distintos, com o objetivo de assegurar a precisão dos contornos e a consistência dos dados empregados no treinamento. Após a conclusão das duas segmentações, é gerada uma terceira classe de interesse, denominada artefato inviabilizante, obtida por meio da operação de intersecção entre as máscaras do ventrículo esquerdo e dos artefatos. Por fim, todas as máscaras são encaminhadas ao gerenciador de conjunto de dados (DsM).

A partir das máscaras geradas manualmente, são definidas as arquiteturas que compõem o modelo nnU-Net¹⁰, cuja configuração é ajustada automaticamente conforme as características do conjunto de dados. Estão disponíveis diferentes variações da arquitetura U-Net: i) nnU-Net 2D, ii) nnU-Net 3D_{Lowres}, iii) nnU-Net 3D_{Fullres} e iv) nnU-Net 3D *Cascade*. Cada variação pode ser combinada a diferentes dimensões estruturais, *medium*, *large* e *extra large*, e à aplicação opcional da técnica *Residual Encoder* (ISENSEE et al., 2022). A validação interna do modelo de segmentação da fase II segue o mesmo processo realizado durante a fase I. Com os exames e as máscaras previamente organizados no DsM, inicia-se o treinamento do modelo nnU-Net. Para isto, os arquivos de imagem e suas respectivas máscaras são nomeados conforme a estrutura esperada pela rede, e é criado um arquivo no formato JavaScript Object Notation (JSON)¹¹, responsável por descrever as características do conjunto, como modalidade de imagem, classes de segmentação e rótulos correspondentes.

O processo de treinamento do modelo, na etapa inicial do projeto, é conduzido em instância disponibilizada pela *Amazon Web Services* (AWS), integrada ao serviço de nuvem *Elastic Compute Cloud* (EC2), pertencente à família G4, otimizada para cargas de trabalho gráficas e computação de uso geral. O treinamento da nnU-Net é

¹⁰Repositório nnU-Net: <https://github.com/MIC-DKFZ/nnUNet> (ISENSEE et al., 2021a; GOODFELLOW et al., 2016).

¹¹Formato leve para intercâmbio de dados, preferido na transmissão entre servidores e navegadores, sendo alternativa ao XML (BASSETT, 2015).

organizado em quatro fases: i) criação das máscaras de referência, ii) preparação dos dados, iii) treinamento do modelo e iv) validação interna. Nesta última etapa, utiliza-se um subconjunto exclusivo de dados, distinto daquele empregado no treinamento, de modo a garantir que o modelo não tenha sido previamente exposto às instâncias avaliadas. O desempenho é mensurado por meio do D_c , que compara as máscaras geradas pela IA com as máscaras de referência produzidas pelos especialistas.

4.8 Fusão de classes e definição da região do artefato inviabilizante

Para identificar o artefato inviabilizante, é necessária a sobreposição, em um mesmo exame, das duas máscaras produzidas: uma referente ao ventrículo esquerdo e outra aos artefatos. A intersecção entre estas máscaras constitui o critério adotado para definir a inviabilidade da imagem. Sempre que, ao menos, um voxel for classificado simultaneamente como pertencente às duas regiões, este é considerado prejudicial à qualidade da imagem, comprometendo sua análise. A detecção automática destes artefatos pelo modelo de IA permite que a equipe técnica, durante a aquisição do exame, adote condutas mais precisas com vistas à melhoria da qualidade das imagens obtidas.

A nnU-Net apresenta como limitação a capacidade de armazenar apenas um rótulo inteiro por voxel nas máscaras de segmentação. Para contornar esta restrição no treinamento de classes sobrepostas, adota-se a técnica de segmentação por regiões (*region-based segmentation*). Nesta abordagem, definem-se regiões-alvo no arquivo de configuração JSON, como combinações de rótulos originais. Durante o treinamento, a rede é configurada para prever um canal distinto para cada região definida. Na etapa de inferência, estas regiões são reconvertidas em único mapa de rótulos, conforme a prioridade estabelecida no arquivo de configuração, assegurando que rótulos mais específicos sobrescrevam os mais genéricos. Esta técnica realiza a divisão dos pixels da imagem em agrupamentos homogêneos, considerando a distância entre os atributos que definem o espaço de características da imagem (MAZOUZI; GUESSOUM, 2021).

Em diversos cenários de segmentação, as classes rotuladas (*label*) podem não coincidir exatamente com as regiões de interesse utilizadas na avaliação final ou na aplicação clínica. Além disto, como no presente estudo, pode haver intersecção entre as classes, resultando em áreas sobrepostas. Para lidar com esta situação, estabelece-se um mapeamento de regiões compostas, formadas pela combinação de uma ou mais

classes originais: i) **label 1** corresponde ao ventrículo esquerdo, ii) **label 2** aos artefatos e iii) **label 3** à intersecção entre ambas. Desta forma, o modelo é treinado para prever diretamente estas regiões compostas, favorecendo a aprendizagem de estruturas funcionalmente relevantes. Na prática, esta abordagem permite que a rede aprenda padrões combinados, o que pode facilitar a identificação de características críticas, sobretudo quando a área de intersecção possui significado clínico.

Ainda em razão da limitação da nnU-Net em lidar com classes sobrepostas, após o treinamento e durante a inferência, a saída considerada é aquela em formato de probabilidades ao invés daquela com aplicação de *Softmax*, no qual cada vóxel recebe uma probabilidade de pertencimento a cada classe de interesse. Com base nesse mapa, são definidos limiares que determinam a classificação final de cada vóxel. Como as probabilidades associadas a cada classe são independentes e pertencem ao intervalo fechado $[0, 1]$, torna-se necessário estabelecer um valor de limiar específico para cada classe. Para este fim, aplica-se uma técnica de otimização com base em algoritmos genéticos (CALIXTO et al., 2010), com o objetivo de identificar os limiares que maximizem a métrica de avaliação D_c nas três classes consideradas.

4.9 Validação e integração clínica do modelo proposto

Para quantificar o desempenho do modelo na detecção da **Classe 3** em nível volumétrico, realiza-se a análise da curva *Receiver Operating Characteristic* (ROC) e do valor correspondente da *Area Under the Curve* (AUC). Cada exame $i = 1, \dots, M$ é considerado uma unidade independente de avaliação, dado por:

- **Rótulo verdadeiro** y_i^{true} é definido como:

$$y_i^{\text{true}} = \begin{cases} 1, & \text{se } \exists v \text{ tal que } y_{iv}^{\text{GT}} = 3, \\ 0, & \text{caso contrário,} \end{cases}$$

em que y_{iv}^{GT} representa o rótulo do voxel v no volume de referência (*ground truth*).

- **Pontuação contínua** s_i : como os volumes preditos estão binarizados, utiliza-se a fração de voxels rotulados como 3 na segmentação do modelo

como a representação aproximada probabilística, dada por:

$$s_i = \frac{\sum_{v=1}^{N_i} \mathbf{1}\{\hat{y}_{iv} = 3\}}{N_i}, \quad (4.1)$$

em que N_i é o número total de voxels no volume i , e \hat{y}_{iv} é o rótulo predito para o voxel v .

A pontuação contínua s_i não é uma probabilidade real estimada por um classificador probabilístico, mas sim a fração de voxels classificados como pertencentes à **Classe 3** em determinado volume predito. Como esta fração pode ser interpretada como um indicativo de confiança ou intensidade de presença da **Classe 3**, ela serve como a aproximação funcional da probabilidade de que o exame contenha esta classe. A partir dos pares $[y_i^{\text{true}}, s_i]$, calculam-se, para todos os limiares $\tau \in [0, 1]$, os índices:

$$\text{TPR}(\tau) = \frac{\text{TP}(\tau)}{\text{TP}(\tau) + \text{FN}(\tau)}, \quad (4.2)$$

$$\text{FPR}(\tau) = \frac{\text{FP}(\tau)}{\text{FP}(\tau) + \text{TN}(\tau)}, \quad (4.3)$$

em que TP, FP, FN e TN correspondem, respectivamente, a verdadeiros positivos, falsos positivos, falsos negativos e verdadeiros negativos, definidos com base no limiar τ . O conjunto de pontos $(\text{FPR}(\tau), \text{TPR}(\tau))$ define a curva ROC. A área sob essa curva (AUC) é calculada pelo método do trapézio, de acordo com a implementação da função `auc` para versões $v \geq$, dada por:

$$\text{AUC} = \int_0^1 \text{TPR}(\text{FPR}^{-1}(x)) dx. \quad (4.4)$$

Valores de AUC iguais a 0,5 indicam desempenho equivalente ao acaso, enquanto valores próximos de 1,0 correspondem a classificação quase perfeita. Para fins comparativos, cada diretório de predições é tratado como um modelo distinto. As respectivas curvas ROC são exibidas em único gráfico, com os valores de AUC indicados na legenda, permitindo avaliação visual e quantitativa do desempenho relativo.

O processo de validação do sistema completo envolve duas etapas distintas. A primeira, de caráter quantitativo, consiste na comparação entre segmentações manuais do ventrículo esquerdo e dos artefatos, realizadas por especialistas na plataforma 3D *Slicer*, e as segmentações geradas pelo método proposto. Esta comparação é realizada com base na métrica D_c , que quantifica a concordância entre as máscaras produzidas pela metodologia e aquelas consideradas como referência. Além disso, a capacidade de classificação entre imagem viável e inviável também é avaliada. A segunda etapa, de natureza qualitativa, é conduzida por médicos nucleares com experiência na interpretação de imagens de CPM, os quais avaliam visualmente as segmentações automáticas. Nesta análise, os especialistas emitem pareceres sobre o delineamento dos contornos e a capacidade do modelo em identificar corretamente o ventrículo esquerdo e os artefatos.

Na segunda etapa, os especialistas recebem os exames originais anonimizados, as segmentações manuais e as segmentações geradas pelo modelo de IA, sem qualquer indicação sobre sua origem, garantindo uma análise cega. Após a avaliação qualitativa, cada especialista atribui um valor de concordância para cada segmentação, utilizando uma escala percentual de 20%, 40%, 60%, 80% ou 100%. Os resultados desta avaliação são analisados por meio do coeficiente κ de Cohen, o qual complementa as análises quantitativas com base no D_c , oferecendo medida adicional da consistência e da confiabilidade do modelo proposto. Após a validação, o modelo pode ser incorporado ao fluxo de produção, passando a gerar automaticamente as máscaras de segmentação. Quando um novo exame é inserido no DsM, o modelo de IA é ativado para produzir a máscara correspondente, que é então armazenada e disponibilizada no aplicativo visualizador. Esta funcionalidade permite que o médico especialista responsável compare o exame original sem segmentação com a versão segmentada pelo modelo, auxiliando na interpretação clínica.

4.10 Considerações finais

São apresentadas neste capítulo os materiais e métodos para realização do exame de CPM, gestão dos dados, modelo de predição com a segmentação manual do ventrículo esquerdo, durante a fase I e artefatos durante a fase II do projeto para treinamento da IA e validação qualitativa e quantitativa do sistema. O próximo capítulo apresenta os resultados obtidos pela aplicação da metodologia proposta durante as duas etapas do trabalho.

CAPÍTULO 5

RESULTADOS

Nesta seção, são apresentados os principais achados decorrentes da aplicação da metodologia desenvolvida para segmentação automatizada das paredes do ventrículo esquerdo e identificação de artefatos em imagens de CPM. Inicialmente, descrevem-se os procedimentos de coleta, anonimização e segmentação manual dos dados, que serviram de base para o treinamento do modelo de IA. Apresenta-se também a re-aplicação do modelo previamente treinado para segmentação do ventrículo esquerdo, com resultados auxiliares que sustentam a etapa posterior de análise de artefatos. Na sequência, são detalhados o treinamento e a validação do segundo modelo preditivo, voltado à segmentação dos artefatos, utilizando a arquitetura nnU-Net com configuração independente. São apresentados os coeficientes obtidos nas etapas de validação interna e externa, incluindo as métricas de sobreposição entre as segmentações manuais e automatizadas.

Por fim, são expostos os resultados da modelagem da interferência diagnóstica ocasionada por artefatos, com análises quantitativa e qualitativa conduzidas por especialistas. O conjunto de resultados permite avaliar tanto o desempenho técnico da abordagem quanto sua aplicabilidade em cenários clínicos reais. Em seguida, procede-se à discussão dos achados. O capítulo de resultados é então, estruturado em duas partes principais: i) identificação das paredes do ventrículo esquerdo e ii) identificação de artefatos em cintilografia miocárdica, ambas utilizando técnicas de inteligência artificial.

5.1 Obtenção e pré-tratamento dos dados

Os dados foram coletados no Hospital Israelita Albert Einstein, São Paulo/Brasil, durante fevereiro e março de 2023. A pesquisa seguiu os requisitos do comitê de ética e foi aprovada com o número CAAE: 64328922.9.0000.0071. Para a realização da CPM, foi empregado o protocolo padrão com aquisição em repouso em decúbito dorsal. O único critério de exclusão foi a assinatura do TCLE, assim, todos os pacientes que assinaram o TCLE tiveram suas imagens de repouso avaliadas. Todos os exames tinham laudos, mas foram utilizadas apenas cópias das imagens em DICOM para este estudo, ficando as originais armazenadas no PACS. Os dados demográficos foram coletados e registrados no REDCap pela investigadora principal, com nenhum

outro pesquisador tendo acesso aos dados sensíveis dos pacientes. Após a coleta dos dados demográficos, os exames foram anonimizados para garantir a privacidade dos pacientes durante a análise. Somente a pesquisadora principal tem acesso à identidade do paciente (ID) associado ao exame, que está no formulário do REDCap. Foram analisados $N = 83$ pacientes, com idades variando de 22 a 88 anos, sendo a maioria, 88%, do gênero masculino, como disposto na Tabela 5.1, no qual μ é a média, σ é o desvio padrão e Min , Max , **F** e **M** são as variáveis mínimo, máximo, feminino e masculino, respectivamente. Cada exame consiste em 50 imagens (ou fatias) a serem segmentadas, representando desafio significativo em termos de trabalho de segmentação.

Tabela 5.1 - Características demográficas dos participantes.

Idade [anos]			Gênero	
μ and σ	Min	Max	F	M
62 ± 13	22	88	10 – 12%	73 – 88%

Na Tabela 5.1, os valores de μ são acompanhados do σ , e os valores absolutos da quantidade de indivíduos de cada gênero são acompanhados da porcentagem em relação ao total de indivíduos N . Todas as imagens de CPM na fase de repouso foram revisadas por especialistas, que identificaram apenas o ventrículo esquerdo em 47 indivíduos, representando 56,6% dos pacientes estudados. Além disto, em 37 indivíduos, o que equivale a 44,6% de N , foi necessário realizar aquisição adicional em posição pronada para garantir a qualidade da imagem para avaliação médica posterior, resultando em aumento no tempo da aquisição dos exames. Após a avaliação inicial, os especialistas realizaram a segmentação manual das paredes dos ventrículos esquerdo em imagens de repouso de $n = 40$ pacientes usando a Plataforma 3D *Slicer*. A Figura 5.1 apresenta o exemplo de segmentação manual dos ventrículo esquerdo realizada no 3D *Slicer*, com a máscara de segmentação indicada na cor verde no eixo longo vertical (ELV), eixo curto (EC) e eixo longo horizontal (ELH), bem como a representação do ventrículo.

Na Figura 5.1, no módulo *Segment Editor* do 3D *Slicer*, foi selecionada a ferramenta *Eraser* para apagar regiões que não compõem o ventrículo esquerdo, logo após ter sido realizada a seleção de estruturas com intensidade de pixel semelhante às do ventrículo esquerdo. Regiões consideradas ventrículo esquerdo foram mantidas rea-

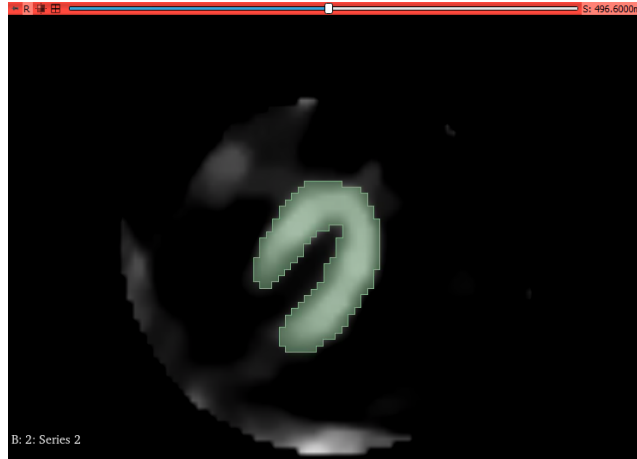


Figura 5.1 - Segmentação manual dos ventrículo esquerdo produzida na Plataforma 3D Slicer.

lizando a seleção de estruturas pela ferramenta *threshold*. Os dados utilizados foram criptografados e os dados sensíveis, apagados nas cópias a serem utilizadas, tornando impossível a recuperação dos códigos e dados fictícios gerados. Os dados dos pacientes permaneceram apenas nas imagens originais, e a relação entre as imagens resultantes da predição e as originais ocorreu somente pela ID. Quanto ao pré-tratamento dos dados, foi ajustado automaticamente pela nnU-Net, que configurou a rede e o pós-processamento para as tarefas de segmentação de imagens, eliminando a necessidade de ajustes manuais. Esta capacidade resultou em alto desempenho e simplificou o desenvolvimento de modelos de aprendizado profundo. Foram incluídas automaticamente etapas como normalização conforme o tipo de imagem, reamostragem para o espaçamento isotrópico, recorte e preenchimento para uniformizar tamanhos de imagem, além do aumento de dados adaptativo.

5.2 Treinamento e validação interna do modelo de predição: Fase I

Com a capacidade da nnU-Net de gerar modelos para cada tarefa de segmentação fornecida durante o treinamento, foram atribuídos rótulos a cada tipo específico de estrutura (classe), indicando a qual classe pertence o *pixel* correspondente. Durante o treinamento, foram utilizados subconjuntos próprios específicos de dados para validação em cada iteração (*fold*), e assim, o número de modelos gerados foi determinado pelo número de tarefas de segmentação definidas no conjunto de dados. Neste trabalho, estabeleceu-se $k = 5$, e cada modelo foi treinado ao longo de 1000 épocas. Os dados foram divididos em dois grupos, separados de forma sequencial:

as imagens dos primeiros 40 pacientes foram utilizadas para treinamento, e as 43 seguintes, para os testes de validação externa do sistema de predição.

Na configuração 2D da nnU-Net, a etapa de treinamento do modelo de segmentação foi realizada utilizando-se o subconjunto próprio com 40 imagens junto às suas máscaras correspondentes. Deste conjunto, 31 imagens foram destinadas ao treinamento e as nove restantes, reservadas para o teste de validação interna do modelo. Foi adotada a técnica de validação cruzada *k-fold* durante o treinamento, na qual cada *fold* resultou na formação de cinco modelos únicos. No subconjunto de teste, utiliza-se os cinco modelos gerados em forma de *ensemble*, combinando as previsões para capturar aspectos distintos dos dados. Foi alcançado o $D_c = 87\%$ e $\sigma \pm 6\%$. A Figura 5.2 apresenta a curva de *Dice* com a distribuição das pontuações da medida de sobreposição entre a segmentação prevista pelo modelo e a segmentação realizada no 3D *Slicer* ao longo das épocas de treinamento.

O gráfico do tipo violino apresenta a distribuição das pontuações do D_c obtidas na validação interna do modelo, aplicada ao subconjunto de teste. O eixo vertical indica os valores do D_c , que variam entre 0,65 e 1,00, enquanto a largura da figura ao longo do eixo horizontal representa a densidade de probabilidade associada a cada faixa de valores. A espessura em cada nível vertical reflete a frequência relativa das pontuações: quanto mais larga a região, maior a concentração de valores naquela faixa. Observa-se uma distribuição assimétrica, com concentração principal em torno de 0,90 e alongamento inferior, sugerindo que a maior parte das segmentações apresentou alto grau de sobreposição com a máscara de referência, embora existam casos isolados com desempenho inferior. A Figura 5.2 inclui ainda uma barra central (mediana) e linhas que indicam o intervalo interquartil, permitindo a visualização conjunta da tendência central, da dispersão e de possíveis valores atípicos de forma mais intuitiva que representações tradicionais, como histogramas.

Na Figura 5.3, foram apresentadas imagens da CPM utilizadas como exemplo na demonstração do corte tomográfico do ventrículo esquerdo no eixo longo. Na Figura 5.3(a), foi exibida a imagem original do exame, que destacou o corte tomográfico sem anotações ou máscaras, apresentando as variações de intensidade características do exame de cintilografia, importante para o ponto de partida em avaliações e segmentações. Esta imagem original apresenta a parede septal, o ápice e a parede lateral do ventrículo esquerdo. Na Figura 5.3(b), a máscara de segmentação manual foi apresentada na cor verde, produzida na Plataforma 3D *Slicer* e utilizada como




Figura 5.2 - Curva de *Dice* com a distribuição das pontuações na validação interna do modelo no subconjunto de teste.

referência, destacando a parte específica do miocárdio com perfusão. Por fim, na Figura 5.3(c), a segmentação realizada pelo método proposto foi apresentada na cor salmão, com a máscara sendo criada automaticamente pelo modelo proposto de IA.

A Figura 5.3(d) apresenta a sobreposição entre as duas máscaras, sendo que os traços em vermelho correspondem à subtração entre as Figura 5.3(b) e Figura 5.3(c), utilizada para avaliar a precisão do modelo proposto em relação à segmentação manual. A análise desta sobreposição permitiu identificar convergências e discrepâncias entre as técnicas automática e manual. Tal comparação é relevante para a validação interna do modelo, considerando que a segmentação manual é adotada como padrão ouro. No exemplo real apresentado na Figura 5.3(d), a similaridade entre as máscaras resultou em valor médio de *Intersection over Union* (IoU) igual a 0,8.

5.3 Validação externa do sistema: Fase I

A validação externa, também denominada validação da solução, é processo necessário para verificar a capacidade do modelo de generalizar para dados inéditos, não utilizados durante as fases de treinamento ou testes anteriores. Este método envolve o uso de subconjunto de dados separado, excluído de qualquer fase de treinamento ou validação interna, com o objetivo de avaliar a eficiência do modelo. O intuito é garantir que o modelo demonstre robustez e confiabilidade quando aplicado em contextos reais, superando as limitações do ambiente de desenvolvimento controlado e validando sua viabilidade e eficiência em cenários autênticos.




Figura 5.3 - Corte tomográfico do ventrículo esquerdo no eixo longo: (a) original, (b) segmentação manual, (c) segmentação com a metodologia proposta e (d) sobreposição da Figura 5.3(b) e Figura 5.3(c).

Neste projeto piloto, os N exames foram divididos em três partes, com 31 usados para treinamento, nove para testes (validação interna) e 43 para a validação externa do sistema. Os 43 exames do subconjunto dedicado à validação foram analisados pela ferramenta de IA proposta, alcançando média de $\overline{D_c} = 88,46\%$ com desvio padrão de $\sigma \pm 7,48\%$. A Figura 5.4 apresenta a curva de *Dice* com a distribuição das pontuações de sobreposição entre a segmentação prevista pelo sistema proposto e a segmentação realizada no 3D *Slicer* pelo especialista.

O gráfico de distribuição das pontuações do D_c obtidas na validação externa do sistema foi realizada com exames completamente independentes das fases de treinamento e validação interna. Assim como na Figura 5.2, o eixo vertical representa os valores de D_c , e a largura do gráfico no eixo horizontal expressa a densidade de probabilidade. Observa-se uma concentração ainda mais acentuada de valores entre 0,90 e 0,95, com perfil de distribuição mais simétrico, indicando desempenho

uniforme do modelo diante de dados inéditos. A cauda inferior é mais estreita, o que sugere menor ocorrência de segmentações com baixo desempenho (abaixo de 0,80), reforçando a capacidade de generalização do sistema. A mediana permanece próxima de 0,90, com baixa dispersão, demonstrando estabilidade frente a variações não observadas durante o treinamento. Esta forma de visualização contribui para a avaliação qualitativa da consistência do modelo em diferentes contextos clínicos.

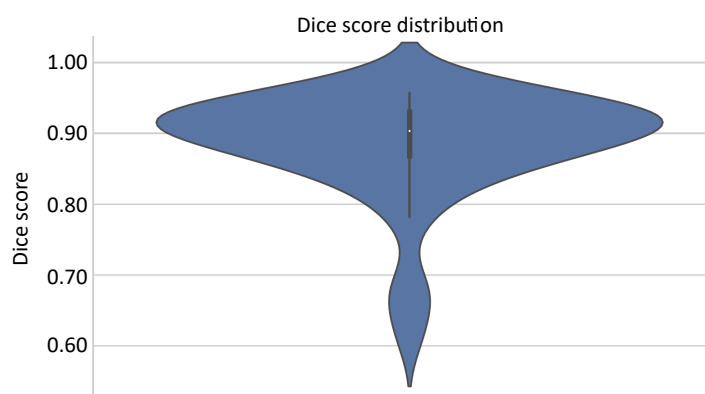


Figura 5.4 - Curva de *Dice* com a distribuição das pontuações na validação externa do sistema.

No subconjunto de 43 exames, três foram selecionados aleatoriamente para serem encaminhados aos especialistas. Cada exame recebeu uma designação, como Teste 1, Teste 2 e Teste 3, organizados em pastas separadas. Cada exame consiste em 50 fatias (imagens volumétricas), exigindo que cada especialista analise 150 imagens. Cada pasta continha a imagem volumétrica anonimizada, nomeada como imagem **original**, imagens da máscara de segmentação **criada manualmente** por um cientista biomédico especializado em medicina nuclear e as imagens da máscara **gerada pela ferramenta de IA**, ambas focadas exclusivamente nas paredes do ventrículo esquerdo. As máscaras foram aleatorizadas e agrupadas em dois conjuntos, chamados de Máscara 1 e Máscara 2, garantindo assim que os médicos especialistas M_N encarregados da avaliação da ferramenta proposta fossem incapazes de distinguir qual máscara foi produzida pela IA ou pelo especialista biomédico.

Três médicos especializados em medicina nuclear, M_{N_1} com 18 anos de experiência, M_{N_2} com 20 anos de experiência e M_{N_3} com 12 anos de experiência, avaliaram de forma independente e cega o delineamento das paredes do ventrículo esquerdo em cada máscara, seguindo os critérios definidos na metodologia. Esta análise apresen-

tou que, na maioria das vezes, houve alto grau de concordância entre os especialistas, com as avaliações indicando entre 80% e 100% de concordância no delineamento das máscaras em ambos os grupos, como disposto na Tabela 5.2. A Figura 5.5 apresenta visualmente os resultados, exibindo nas linhas o Teste 1, Teste 2 e Teste 3, e nas colunas, respectivamente, as imagens originais, as máscaras geradas pela IA e as máscaras criadas manualmente pelos especialistas.

Tabela 5.2 - Avaliação médica geral dos 9 conjuntos de imagens apresentada aos médicos.

Itens	IA	Manual
Concordo com 100% do posicionamento da máscara	4	4
Concordo com 80% do posicionamento da máscara	5	4
Concordo com 60% do posicionamento da máscara	0	1




Figura 5.5 - Imagens encaminhadas para os M_N encarregados da avaliação de concordância entre as segmentações da IA e especialista biomédico.

Na Tabela 5.3 são dispostas as avaliações individuais dos testes e suas concordâncias. Na análise qualitativa realizada pelos médicos especialistas M_N , foi observado que ocorreu concordância de pelo menos 80% quanto ao posicionamento das máscaras geradas pela ferramenta proposta. Observa-se, no Teste 1, que registrou a maior divergência entre os avaliadores, atribuiu-se a menor pontuação à máscara manual.

A discrepância foi principalmente devido à proximidade do coração com a zona de artefato, resultando em concordância de 60% para o posicionamento da máscara manual.

Tabela 5.3 - Avaliação médica individual por teste.

Itens	Avaliação					
	Teste 1		Teste 2		Teste 3	
	IA	Manual	IA	Manual	IA	Manual
Concordo com 100%	1	0	1	2	2	2
Concordo com 80%	2	2	2	1	1	1
Concordo com 60%	0	1	0	0	0	0

5.4 Obtenção e pré-tratamento dos dados clínicos para Fase II

Com as máscaras do ventrículo esquerdo previamente segmentadas, deu-se início à segunda etapa do processo, dedicada à segmentação automatizada dos artefatos em imagens de CPM. Esta etapa foi conduzida de forma independente, por meio de um novo modelo treinado especificamente para identificar regiões extracardíacas com potencial para comprometer a interpretação diagnóstica. A construção deste modelo demandou ajustes na estratégia de rotulagem, bem como o desenvolvimento de uma métrica de interseção entre estruturas anatômicas relevantes, permitindo quantificar o grau de interferência provocado pelos artefatos.

Dos 83 exames utilizados na etapa de segmentação do ventrículo esquerdo, apenas 70 puderam ser aproveitados na fase de segmentação dos artefatos, em decorrência do extravio de 13 exames durante o processo de recuperação no sistema VNA. Considerando que cada exame é composto por 50 imagens tomográficas, o conjunto final desta etapa foi constituído por 3.500 imagens. A segmentação automatizada foi realizada por meio da arquitetura nnU-Net, que permite a geração de modelos específicos para cada tarefa de segmentação definida durante o treinamento. Foram atribuídos rótulos a cada estrutura de interesse, de modo que cada voxel fosse corretamente associado à respectiva classe. A quantidade de modelos gerados foi determinada conforme o número de tarefas de segmentação presentes no conjunto de dados.

Nas configurações da nnU-Net, o treinamento do modelo de segmentação dos artefatos foi realizado com um subconjunto composto por 70 exames e suas respectivas

máscaras. Os dados foram divididos de forma sequencial, sendo 49 exames utilizados para o treinamento e os 21 restantes destinados aos testes. Destes, três exames foram reservados para validação externa. Adotou-se a técnica de validação cruzada com $k = 5$ partições, com treinamento de cinco modelos distintos ao longo de 1.000 épocas. Para a avaliação no subconjunto de teste, as previsões dos cinco modelos foram combinadas por meio de um *ensemble*, com o objetivo de capturar variações complementares entre as segmentações geradas. Esta estratégia permitiu avaliar a capacidade de generalização do modelo frente à variabilidade morfológica dos artefatos extracardíacos.

Com o objetivo de identificar os melhores valores de limiar para binarização das máscaras preditas, buscou-se maximizar os coeficientes D_c das três classes: **Classe 1**, correspondente ao ventrículo esquerdo, **Classe 2**, referente ao artefato extracardíaco e **Classe 3**, definida como artefato inviabilizante, resultante da sobreposição entre as máscaras das duas classes anteriores. Para cada variante da nnU-Net, aplicou-se inicialmente a técnica de otimização por busca exaustiva. Neste contexto, a função de avaliação recebe como entrada os valores de limiar correspondentes e retorna como saída o valor de desempenho agregado, calculado com base nos coeficientes de D_c de cada classe, definido por:

$$f(\theta_1, \theta_2) = \frac{1}{3} \sum_{i=1}^N D_{ci} \quad (5.1)$$

no qual θ_1 representa o limiar da **Classe 1**, θ_2 o limiar da **Classe 2** e a **Classe 3** corresponde à interseção entre as máscaras binarizadas da **Classe 1** e da **Classe 2**, caracterizando o artefato inviabilizante. Na expressão (5.1), D_{ci} denota o valor do coeficiente de Dice para cada classe, com $N = 3$ e $i = 1, 2, 3$. Embora a busca exaustiva permita identificar soluções ótimas por meio da avaliação de todas as combinações possíveis, sua aplicação tornou-se inviável neste caso, em razão do elevado custo computacional associado à granularidade exigida nos intervalos de limiar. Para tornar o processo mais eficiente e possibilitar a exploração do espaço contínuo de soluções, optou-se pela utilização do algoritmo genético (AG). Esta abordagem heurística permitiu a obtenção de soluções próximas do ótimo, com custo computacional reduzido, mantendo desempenho satisfatório. O processo de treinamento e validação interna do modelo de predição com o AG é definido pelo Algoritmo 5.4.

[!h] Treinamento e validação interna do modelo de predição. [1] Conjunto de imagens \mathcal{I} e máscaras \mathcal{M} de 40 pacientes Modelos treinados $\mathcal{M}_{\text{models}}$ e métricas de validação

Dividir \mathcal{I} e \mathcal{M} em $k = 5$ *folds* para validação cruzada

cada *fold* _{i} em 1 até 5 Separar dados de treino e validação: $(\mathcal{I}_{\text{train}}^i, \mathcal{M}_{\text{train}}^i)$ e $(\mathcal{I}_{\text{val}}^i, \mathcal{M}_{\text{val}}^i)$ Inicializar modelo nnU-Net _{i} com configuração 2D Treinar nnU-Net _{i} por 1000 épocas com $(\mathcal{I}_{\text{train}}^i, \mathcal{M}_{\text{train}}^i)$ Validar nnU-Net _{i} em $(\mathcal{I}_{\text{val}}^i, \mathcal{M}_{\text{val}}^i)$ Armazenar modelo treinado em $\mathcal{M}_{\text{models}}$

Aplicar *ensemble* dos 5 modelos sobre o subconjunto de teste interno ($n = 9$ imagens) Calcular métricas de desempenho (ex: Dice, IoU) Reportar $D_c = 87\% \pm 6\%$ e IoU médio

$\mathcal{M}_{\text{models}}$

A Tabela 5.4 apresenta os limiares otimizados para cada variante da nnU-Net, juntamente com os coeficientes D_c correspondentes às três classes avaliadas: D_{c1} para a **Classe 1**, D_{c2} para a **Classe 2** e D_{c3} para a **Classe 3**. Os parâmetros T_1 e T_2 referem-se aos limiares aplicados na binarização das máscaras das classes 1 e 2, respectivamente. A métrica $f(\theta_1, \theta_2)$ corresponde ao valor da função de avaliação definida na expressão (5.1).

Tabela 5.4 - Valores otimizados para os limiares de cada variante da nnU-Net.

Modelo	T_1	T_2	D_{c1}	D_{c2}	D_{c3}	$f(\theta_1, \theta_2)$
2D	0.956864	0.072157	0.9094	0.7822	0.3333	0.6750
2D-ResEncM	0.968804	0.011103	0.9057	0.7764	0.3416	0.6746
2D-ResEncL	0.970516	0.031020	0.9062	0.7752	0.3375	0.6729
3D-fullres	0.005688	0.299049	0.9276	0.8272	0.3381	0.6976
3D-fullres-ResEncM	0.574508	0.074236	0.9332	0.8267	0.3333	0.6977
3D-fullres-ResEncL	0.067409	0.490507	0.9338	0.8262	0.3401	0.7000

Apesar dos baixos valores observados para o coeficiente D_{c3} , sua inclusão na função de avaliação $f(\theta_1, \theta_2)$ é justificada pela relevância clínica da **Classe 3**, correspondente ao artefato inviabilizante. Embora esta classe apresente baixa frequência relativa, ela representa casos em que a sobreposição entre estruturas críticas pode comprometer a interpretação diagnóstica. Neste contexto, o coeficiente D_{c3} expressa a capacidade do modelo em identificar situações de risco, atuando como elemento de

penalização na função objetivo. Sua presença impede que configurações com desempenho satisfatório nas classes dominantes (**Classe 1** e **Classe 2**) sejam favorecidas à custa de falhas relevantes na **Classe 3**. Ainda que seus valores absolutos sejam reduzidos, as variações de D_{c3} entre os modelos fornecem informações importantes sobre a sensibilidade da arquitetura a casos extremos e sua aptidão para captar interseções clinicamente significativas. A Figura 5.6 apresenta os *boxplots* da distribuição dos valores de D_c para a **Classe 1** e a **Classe 2**.




Figura 5.6 - *Boxplot* da métrica D_c para cada modelo nas **Classe 1** e **Classe 2**.

A Figura 5.6 apresenta os *boxplots* da métrica D_c apenas para a **Classe 1** e a **Classe 2**, por serem as mais representativas em termos volumétricos. A **Classe 3**, correspondente ao artefato inviabilizante, foi omitida da visualização gráfica devido à sua baixa frequência relativa, o que comprometeria a interpretação estatística dos *boxplots*. Apesar disto, esta classe foi plenamente considerada na função de avaliação $f(\theta_1, \theta_2)$, justamente por representar situações de risco clínico. O D_{c3} atua como fator de penalização na otimização dos limiares, impedindo que o desempenho desejado em classes dominantes oculte falhas relevantes nos casos críticos. Assim, mesmo não sendo graficamente explorável pelas limitações amostrais, a **Classe 3** possui papel funcional decisivo na calibração e avaliação do modelo.

O modelo 3D-fullres-ResEncL obteve o melhor desempenho global, com $f(\theta_1, \theta_2) = 0,7000$, além dos maiores valores de $D_{c1} = 0,9338$ e $D_{c3} = 0,3401$. Para a **Classe 1**, todas as variantes mantiveram desempenho elevado e consistente, com valores me-

dianos de $D_{c1} \geq 0,90$ e baixa dispersão, indicando alta estabilidade na segmentação do ventrículo esquerdo. Em contrapartida, a **Classe 2**, correspondente aos artefatos de interferência, apresentou desempenho inferior em todas as variantes, com valores medianos entre $0,80 \leq D_{c2} \leq 0,85$, maior variabilidade e presença frequente de outliers. Esta discrepância sugere que a segmentação de artefatos é mais sensível à arquitetura da rede e aos parâmetros de entrada, exigindo maior refinamento dos mecanismos de detecção.

Assim, o modelo 3D-fullres apresentou desempenho ligeiramente superior às demais variantes tridimensionais para a **Classe 2**, com maior concentração dos valores de D_c em patamares elevados. As variantes 2D, por sua vez, exigiram limiares mais altos, T_1 e T_2 , sobretudo para a **Classe 1**, indicando maior seletividade na ativação dos mapas preditivos. Embora a **Classe 3** não esteja representada graficamente, análises complementares indicam que os valores de D_{c3} apresentaram instabilidade e tendência à subsegmentação ou incorreta fusão com estruturas da **Classe 2**. Ainda assim, os coeficientes permaneceram em faixa estreita $0,3333 \leq D_{c3} \leq 0,3416$, sugerindo certa estabilidade. A avaliação desta classe requer amostras ampliadas e estratégias específicas de balanceamento. A abordagem atual, ao priorizar as classes dominantes, permite que ambiguidades residuais sejam tratadas em etapas posteriores, como a correção semiautomática por especialistas.

Os resultados obtidos com a otimização dos limiares reforçaram a adequação do uso da função de avaliação $f(\theta_1, \theta_2)$. Esta estratégia permitiu balancear o desempenho entre as três classes envolvidas. Observou-se que os modelos tridimensionais com codificadores residuais, em especial na configuração ResEncL, apresentaram melhor equilíbrio entre as segmentações, com desempenho superior em D_{c1} e D_{c3} , além da maior $f(\theta_1, \theta_2)$. Com base nestes resultados, torna-se necessário avaliar não apenas a qualidade das segmentações geradas, mas também o impacto clínico potencial dos artefatos identificados, especialmente daqueles que se sobrepõem ao ventrículo esquerdo e podem comprometer a interpretação diagnóstica.

5.5 Avaliação preditiva da interferência diagnóstica

Com base nos resultados da otimização dos limiares e com o objetivo de avaliar o impacto clínico dos artefatos identificados, foi construído um modelo de regressão logística binária para estimar a probabilidade de inviabilização da imagem. A variável independente considerada foi a menor distância entre a máscara do artefato

e a do ventrículo esquerdo. Utilizou-se um conjunto de 150 imagens rotuladas por especialistas, que indicaram, para cada caso, se as segmentações eram clinicamente aceitáveis ou comprometidas. O modelo foi ajustado com o *solver liblinear*, adotando o balanceamento automático das classes e mantendo os hiperparâmetros em seus valores padrão.

O ponto de corte ótimo do escore logístico foi determinado com base no critério de Youden, métrica clássica utilizada para definir o limiar de decisão em classificadores binários, especialmente em cenários com desbalanceamento entre classes. Este cálculo foi aplicado à própria base de validação, resultando em um limiar ótimo de 0,853. A área sob a curva ROC (AUC) obtida foi de 0,946, indicando elevada capacidade discriminativa do modelo na tarefa de classificação entre imagens utilizáveis e inviabilizadas por artefatos. As seis arquiteturas de segmentação foram avaliadas quanto à capacidade de gerar máscaras do ventrículo esquerdo e dos artefatos, utilizando um conjunto de 21 exames de teste. Para cada par de máscaras preditas, foi calculada a menor distância entre o artefato e o ventrículo esquerdo, por meio de mapas de distância gerados com a biblioteca ITK.

Em seguida, aplicou-se o modelo logístico treinado para estimar a probabilidade de interferência diagnóstica. A classificação final foi determinada pela comparação desta probabilidade com o limiar global obtido na etapa de validação, fixado em 0,853 (limiar ótimo). A avaliação do desempenho foi conduzida com base em métricas clássicas de predição binária, incluindo: área sob a curva ROC (AUC), área sob a curva de precisão-revocação (AUPR), acurácia (ACC), sensibilidade (SEN), especificidade (SPE) e precisão (PRE), todas calculadas em relação aos rótulos de referência definidos por especialistas. Estas métricas foram computadas para uma regra-base que utiliza exclusivamente a distância mínima entre artefato e ventrículo esquerdo, sem aplicação do modelo logístico.

A Tabela 5.5 dispõe os resultados obtidos para cada arquitetura avaliada. A métrica AUC expressa a capacidade discriminativa do modelo, com valores mais próximos de 1 indicando maior desempenho, AUPR é robusta a desbalanceamentos e útil em conjuntos com menor proporção de positivos, ACC corresponde à proporção total de classificações corretas, SEN representa a capacidade de identificar corretamente os exames com interferência e SPE indica a proporção de exames sem interferência corretamente reconhecidos. O modelo 2D-ResEncM obteve o melhor desempenho global, com $AUC=0,850$, $AUPR=0,925$ e $ACC=71,4\%$. Os modelos tridimensionais,

em geral, apresentaram ACC inferior, embora tenham mantido SPE=1 em todos os casos, possivelmente em decorrência do limiar conservador adotado.

Tabela 5.5 - Desempenho da regressão logística no conjunto de teste.

Modelo	n	AUC	AUP	ACC	SEN	SPE
2D	21	0.725	0.863	0.476	0.312	1.000
2D-ResEncL	21	0.775	0.905	0.667	0.562	1.000
2D-ResEncM	21	0.850	0.925	0.714	0.625	1.000
3D-fullres	21	0.825	0.925	0.619	0.500	1.000
3D-fullres-ResEncL	21	0.719	0.877	0.524	0.375	1.000
3D-fullres-ResEncM	21	0.700	0.865	0.476	0.312	1.000

A sensibilidade apresentou variações expressivas entre as arquiteturas, refletindo discrepâncias na qualidade das segmentações e, por conseguinte, nas estimativas de distância empregadas na regressão. Os valores referentes à regra-base, fundamentada exclusivamente na distância mínima entre o artefato e o ventrículo esquerdo, foram omitidos da Tabela 5.5, uma vez que coincidem com os da regressão logística, devido à natureza monótona do classificador em relação à variável de entrada. Na fase de validação, o modelo treinado com dados rotulados alcançou $AUC=0,946$, indicando elevada capacidade discriminativa. No conjunto de teste, entretanto, a $0,700 \leq AUC \leq 0,850$, a depender da arquitetura empregada na segmentação, o que indica que a qualidade das máscaras geradas afeta diretamente a distribuição das distâncias e, por extensão, o desempenho do classificador.

Em contrapartida, a $0,312 \leq SEN \leq 0,625$, indicando tendência do modelo a não identificar adequadamente os casos de interferência, sobretudo nos cenários em que as segmentações apresentaram menor precisão. Esta assimetria sugere que o uso de limiares menos rigorosos ou calibrações específicas por arquitetura pode aumentar a SEN sem comprometer excessivamente a taxa de falsos positivos. Por fim, destaca-se que a amostra de teste foi limitada a 21 exames por modelo, o que implica maior variabilidade estatística e pode inflar as diferenças observadas entre as arquiteturas. Estudos futuros com amostras ampliadas e validação multicêntrica são recomendados para consolidar a aplicabilidade clínica da abordagem e confirmar a consistência dos achados.

5.6 Validação externa e avaliação clínica: fase II

Utilizando o mesmo procedimento de validação externa da fase I, para esta etapa, foram selecionados aleatoriamente três exames a partir de um subconjunto de 21, sendo cada um identificado como Teste 1, Teste 2 e Teste 3, e armazenado em pastas individuais. Cada exame continha 50 imagens (fatias), totalizando 150 imagens a serem analisadas por cada especialista, com foco no ventrículo esquerdo e em artefatos. As pastas incluíam a imagem volumétrica anonimizada, identificada como **original**, a máscara de segmentação **criada manualmente** por profissional biomédico com especialização em medicina nuclear e a máscara **gerada automaticamente pela ferramenta de IA**, ambas centradas nas paredes do ventrículo esquerdo e nos artefatos. As máscaras foram randomizadas e organizadas em dois grupos, denominados Máscara 1 e Máscara 2, de modo a garantir que os médicos especialistas M_{N_i} responsáveis pela avaliação não tivessem conhecimento sobre a origem das segmentações.

Os mesmos três médicos especialistas em medicina nuclear da fase I deste projeto, identificados como M_{N_1} , M_{N_2} e M_{N_3} , realizaram, de forma independente e cega, a avaliação do delineamento das paredes do ventrículo esquerdo e artefatos em cada máscara. Os resultados desta análise indicaram níveis de concordância entre 60%, 80% e 100% para ambas as segmentações, como disposto na Tabela 5.6. A Figura 5.7 apresenta visualmente os três exames submetidos à avaliação qualitativa cega. As linhas correspondem ao Teste 1, Teste 2 e Teste 3, enquanto as colunas exibem, respectivamente, a imagem original da CPM, a segmentação manual realizada por especialista biomédico e a segmentação gerada pela ferramenta de IA proposta. As regiões na cor amarela representam os artefatos, na cor verde o ventrículo esquerdo, e na cor marrom as áreas de interseção entre as duas máscaras, cuja sobreposição pode comprometer a qualidade diagnóstica da imagem.

Tabela 5.6 - Grau de concordância das máscaras respondidas pelos especialistas por tipo de segmentação.

Itens	IA	Manual
Concordo 100% com o posicionamento das máscaras	1	5
Concordo 80% com o posicionamento das máscaras	6	4
Concordo 60% com o posicionamento das máscaras	2	0

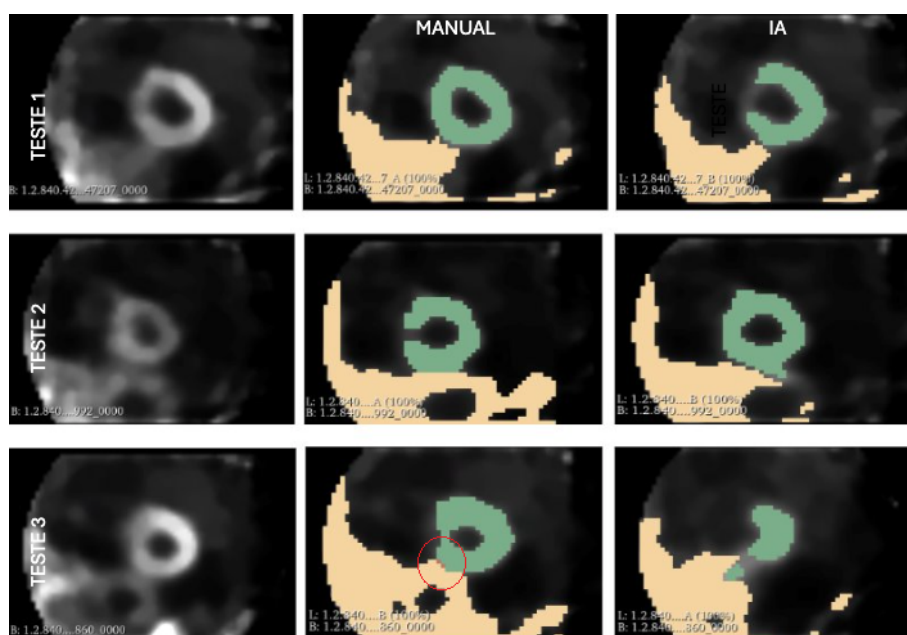


Figura 5.7 - Comparação visual entre segmentações manual e automatizada em três exames distintos.

A Figura 5.7 permite a comparação direta entre a aderência espacial das máscaras geradas pela IA e as segmentações de referência. No Teste 2 e Teste 3, observa-se a sobreposição entre estruturas relevantes, indicada na cor marrom na máscara produzida pelo profissional biomédico, e a proximidade das estruturas e delineado possivelmente influenciaram negativamente as avaliações dos especialistas, como disposto na Tabela 5.6. A Tabela 5.7 dispõe as avaliações individuais dos testes e os respectivos níveis de concordância. Na análise qualitativa conduzida pelos médicos especialistas M_{N_i} , observa-se concordância igual ou superior a 60% quanto ao posicionamento das máscaras geradas. No Teste 2 e Teste 3, as máscaras produzidas pela ferramenta proposta receberam as menores pontuações. Esta discrepância esteve associada, principalmente, ao posicionamento das máscaras do ventrículo esquerdo em regiões com artefatos, o que resultou em concordância limitada, inclusive para a segmentação manual.

De forma geral, os resultados da validação externa indicam que o modelo proposto é capaz de gerar segmentações com níveis satisfatórios de concordância com especialistas, inclusive em exames com presença de artefatos. Embora tenham sido identificadas algumas discrepâncias, especialmente nos casos em que o posicionamento do ventrículo coincidiu com regiões afetadas por artefatos, a ferramenta apresentou desempenho consistente na maior parte dos testes avaliados. Estes resultados

Tabela 5.7 - Avaliação médica individual por teste.

Itens	Avaliação					
	Teste 1		Teste 2		Teste 3	
	IA	Manual	IA	Manual	IA	Manual
Concordo 100%	1	2	0	1	0	2
Concordo 80%	2	1	2	2	2	1
Concordo 60%	0	0	1	0	1	0

reforçam o potencial de aplicação clínica do modelo, particularmente como suporte à triagem e à revisão automatizada de exames, contribuindo para maior eficiência e padronização na análise de CPM.

5.7 Discussão

Este estudo explorou a aplicação de Inteligência Artificial (IA), destacando o uso das redes neurais convolucionais (RNC) e nnU-Net na identificação das paredes do ventrículo esquerdo do coração e artefatos que podem aparecer em imagens de cintilografia de perfusão miocárdica (CPM), com foco no apoio à equipe clínica na avaliação inicial da qualidade dos exames. O diferencial importante da abordagem adotada está na estratégia em três etapas: primeiramente, realiza-se a segmentação do ventrículo esquerdo, em seguida, são identificados os artefatos e, por fim, deriva-se uma terceira classe correspondente à sobreposição entre estas estruturas. Esta modelagem orientada à interferência diagnóstica difere da maioria dos estudos anteriores, que buscam identificar os artefatos diretamente, sem considerar sua relação espacial com regiões críticas. Ao enfatizar o impacto funcional dos artefatos sobre a viabilidade diagnóstica, a proposta contribui com uma nova perspectiva na aplicação de IA à cardiologia nuclear.

A solução proposta utiliza a arquitetura nnU-Net combinada a um processo de segmentação supervisionada, sendo avaliada por meio de métricas quantitativas e análise qualitativa conduzida por especialistas. Os resultados demonstraram desempenho satisfatório, com média de $IoU = 0.8$, coeficientes de Dice médios superiores a 87% para a segmentação do ventrículo esquerdo e valores entre 0,300 e 0,940 para as classes associadas aos artefatos. Estes indicadores indicam a concordância com as segmentações manuais realizadas por profissionais especialistas, destacando avanços significativos na interpretação diagnóstica e superando alguns dos métodos tradicionais, como o manual.

Ainda sobre os artefatos, a regressão logística obteve AUC igual a 0,946 na fase de validação, mantendo desempenho superior a 0,700 nas diferentes arquiteturas avaliadas no conjunto de teste. A validação externa indicou concordância igual ou superior a 60% em todos os casos revisados por médicos especialistas, o que reforça a aplicabilidade do modelo em contextos clínicos reais. Entre as arquiteturas analisadas, a 3D-fullres-ResEncL destacou-se por apresentar os melhores resultados agregados, superando as demais em todas as métricas principais. Tais achados apresentam a capacidade da solução proposta em detectar interferências relevantes na interpretação das imagens, favorecendo a padronização da análise e a redução de erros diagnósticos induzidos por artefatos.

Além do desempenho quantitativo, a aplicabilidade clínica do modelo é ampliada por sua habilidade em identificar automaticamente regiões inviabilizadas por sobreposição entre artefatos e estruturas críticas, um desafio frequente na prática diagnóstica. Esta funcionalidade permite a integração do modelo como etapa preliminar à leitura médica, auxiliando na triagem de exames com qualidade comprometida e promovendo maior racionalização dos fluxos assistenciais. O uso da ferramenta como apoio à decisão pode contribuir para a redução de retrabalhos e para o aprimoramento da segurança diagnóstica, especialmente em ambientes com alta demanda ou recursos limitados.

5.7.1 Comparação com a literatura e avanços metodológicos

Estudos anteriores aplicaram redes convolucionais à análise de CPM, com ênfase na redução de ruído, correção de atenuação e segmentação de estruturas anatômicas. Arquiteturas como a U-Net e suas variantes, incluindo a nnU-Net, têm apresentado elevado desempenho em tarefas de segmentação cardíaca, como demonstrado por Zhu *et al.* (ZHU *et al.*, 2022) e Huang *et al.* (HUANG *et al.*, 2024). No entanto, poucos trabalhos abordaram especificamente a identificação de artefatos, sobretudo considerando sua sobreposição com o ventrículo esquerdo e o impacto funcional decorrente. Esta lacuna metodológica limita a aplicabilidade dos modelos em contextos clínicos nos quais a viabilidade diagnóstica é comprometida por interferências técnicas.

Pesquisas anteriores, referenciadas implicitamente, sugeriram o potencial da IA para aprimorar a precisão diagnóstica e a identificação das paredes do ventrículo esquerdo, enriquecendo o diagnóstico da DAC. Trabalhos como os de Liu *et al.* (2021), Slomka *et al.* (2020) e Eisenberg *et al.* (2022) destacaram o potencial da IA para aprimorar

a interpretação de imagens e a detecção de DAC, oferecendo novas perspectivas sobre a identificação das paredes do ventrículo esquerdo e a melhoria da precisão das segmentações. Esta proposta avança nesta direção ao indicar a eficiência prática da IA em identificar as paredes do ventrículo esquerdo, corroborando a viabilidade e eficiência do modelo de IA em situações clínicas, validado tanto interna quanto externamente.

O presente estudo avança neste cenário ao incorporar uma classe composta de artefato inviabilizante e empregar um algoritmo genético para a otimização de limiares, ampliando as possibilidades de detecção clínica automatizada. Diferentemente de abordagens que priorizam exclusivamente a acurácia morfológica das segmentações, o modelo aqui proposto integra uma etapa de regressão supervisionada voltada à predição do comprometimento clínico. Esta abordagem permite não apenas identificar a presença de artefatos, mas também estimar sua influência sobre a capacidade de interpretação diagnóstica, representando um avanço metodológico relevante com aplicabilidade direta em ambientes assistenciais.

Tais características diferenciam esta proposta das soluções discutidas por Apostolopoulos *et al.* (APOSTOLOPOULOS *et al.*, 2023) e Shanbhag *et al.* (SHANBHAG *et al.*, 2022), nas quais os artefatos são tratados apenas como ruído ou anomalias sem categorização funcional. Além de corroborar evidências recentes sobre o potencial da IA em cardiologia nuclear, como apontado por Nogueira *et al.* (NOGUEIRA *et al.*, 2025), o presente estudo introduz uma abordagem estruturada que combina segmentação morfológica com regressão clínica, aplicando esta estratégia a um problema ainda pouco explorado. A sinergia entre otimização técnica e predição diagnóstica configura um diferencial metodológico com impacto concreto na prática clínica.

Este diferencial torna-se ainda mais relevante diante da ausência, na literatura, de soluções específicas para a identificação sistemática de artefatos e sua interferência na análise funcional do miocárdio. Embora haja avanços expressivos no uso de modelos de IA para análise de imagens de CPM, a maior parte dos estudos concentra-se na detecção de defeitos de perfusão ou na avaliação de estenoses, negligenciando o impacto clínico de distorções provocadas por fatores técnicos, anatômicos ou operacionais. O presente trabalho contribui diretamente para preencher esta lacuna ao propor um modelo capaz não apenas de segmentar os artefatos, mas também de quantificar sua sobreposição com regiões críticas e estimar seu impacto na viabilidade diagnóstica. Esta abordagem possibilita a identificação precoce de exames

comprometidos, seja durante a aquisição das imagens, seja na etapa de revisão, ampliando a segurança e a confiabilidade do processo diagnóstico. O modelo incorpora elementos de explicabilidade e auditabilidade, aspectos fundamentais para sua integração em sistemas clínicos assistenciais.

5.7.2 Limitações e propostas de aprimoramento

Este estudo destaca-se pela abordagem metodológica, desde a coleta até a análise de imagens de CPM, utilizando avanços em IA para aprimorar o diagnóstico da DAC. A otimização das CNN e a adoção de técnicas avançadas como o U-Net++ para mitigar efeitos de atividades extracardíacas marcam progressos importantes na área. Assim, além de enriquecer a prática diagnóstica em cardiologia e medicina nuclear, este trabalho propõe solução economicamente viável para a incorporação clínica destas tecnologias, sublinhando a importância dos avanços tecnológicos no campo da saúde.

A implementação do modelo proposto para ventrículo esquerdo demonstrou ser pioneira na interpretação automatizada de exames de CPM, iluminando novos caminhos na precisão da identificação das paredes do VE, contribuição significativa para a área. Além disto, a concordância elevada nas avaliações de especialistas médicos apresenta a capacidade do modelo de enfrentar a complexidade e a variabilidade na interpretação de imagens médicas, superando desafios, como os observados no Teste 1 da primeira etapa.

Apesar dos resultados apresentados, o modelo ainda enfrenta limitações importantes que devem ser consideradas para sua aplicação plena. Entre as limitações do presente estudo, destaca-se o tamanho reduzido da amostra. A ampliação da coleta de dados é um fator determinante para determinação estatística. Quanto maior o número de segmentações, maior a precisão, menor o erro amostral e maior a possibilidade de identificar padrões, tendências e correlações significativas. Além disso, uma amostra mais abrangente contribui para a generalização dos resultados, mitigando os vieses da heterogeneidade dos indivíduos e aumentando a validade externa do estudo, que permanece limitada composta por apenas três exames avaliados por três especialistas mesmo com o resultado em nível de concordância considerado satisfatório.

O modelo desenvolvido considera exclusivamente imagens obtidas em repouso, sem incluir dados da fase de estresse, o que pode restringir sua aplicabilidade em ava-

liações diagnósticas completas. Outra limitação relevante refere-se à segmentação conduzida de forma independente para artefatos e ventrículo esquerdo, o que pode comprometer o desempenho do modelo em situações de sobreposição estrutural mais complexa. Para superar estas restrições, recomenda-se a ampliação da base de dados com exames multicêntricos e multivariados, envolvendo diferentes protocolos e equipamentos.

Outros desafios metodológicos, como a coleta e o pré-tratamento dos dados em ambientes clínicos, foram superados, apesar das dificuldades impostas pela necessidade de anonimização e conformidade com protocolos éticos.

Sugere-se ainda a adoção de arquiteturas multitarefa, capazes de realizar simultaneamente a segmentação das estruturas e a predição da viabilidade diagnóstica, promovendo maior integração e desempenho. Estratégias de aprendizado federado também podem ser consideradas, especialmente para viabilizar o uso de dados clínicos heterogêneos preservando a privacidade dos pacientes. Entre os desafios metodológicos enfrentados ao longo do estudo, destacam-se as etapas de coleta, anonimização e pré-processamento das imagens clínicas, que exigiram conformidade com normas éticas e operacionais. Apesar destas dificuldades, foi possível estabelecer um fluxo reprodutível e compatível com ambientes clínicos reais, o que reforça a viabilidade prática da solução desenvolvida.

Apesar dos resultados encontrados, algumas limitações técnicas merecem atenção crítica. A sensibilidade do modelo para artefatos com contornos tênues ou localização periférica foi inferior à observada em casos de interferência intensa, sugerindo tendência à subdetecção em padrões menos evidentes. Além disto, a regressão logística, embora eficiente na maioria dos cenários, depende fortemente da distribuição das distâncias segmentadas, o que a torna suscetível a variações introduzidas por pequenas imprecisões nas máscaras. Esta sensibilidade estrutural pode impactar negativamente a generalização do modelo, sobretudo em exames com características anatômicas atípicas. A aplicação de limiares fixos para caracterização de interferência também pode introduzir rigidez na interpretação dos resultados, o que reforça a necessidade de modelos adaptativos em versões futuras da ferramenta. Neste contexto, as direções futuras do trabalho buscam justamente superar estas limitações e expandir a aplicabilidade clínica da ferramenta.

5.7.3 Perspectivas futuras

As perspectivas futuras incluem a adaptação do modelo para ambientes clínicos em tempo real, com integração direta aos sistemas PACS e visualizadores médicos. A incorporação de abordagens multimodais, que combinem imagens de SPECT com dados clínicos e demográficos, tem o potencial de ampliar a acurácia e a capacidade preditiva na identificação de exames comprometidos. Além disto, estratégias de aprendizado contínuo, associadas ao refinamento supervisionado com base no feedback de especialistas, podem favorecer a evolução adaptativa do modelo em contextos operacionais dinâmicos. Destaca-se ainda a possibilidade de incorporar mecanismos de explicabilidade visual, como mapas de atenção e camadas interpretáveis, contribuindo para a transparência da decisão algorítmica e promovendo maior aceitação clínica da IA.

Outra linha promissora refere-se à adoção de arquiteturas avançadas, como o U-Net++, e ao desenvolvimento de estratégias específicas para redução de atividades extracardíacas, que frequentemente interferem na segmentação automatizada. Tais aprimoramentos podem melhorar a precisão das máscaras geradas e reduzir falsos positivos em regiões adjacentes ao coração. Aliados à redução do custo computacional, estes avanços tornam a solução proposta mais atrativa para aplicação em serviços públicos e clínicas com infraestrutura limitada. Em conjunto, estas direções de aprimoramento alinham-se às tendências mais recentes da cardiologia nuclear, que apontam para soluções assistivas, interoperáveis e voltadas à melhoria contínua da qualidade diagnóstica.

CAPÍTULO 6

CONCLUSÃO

Este estudo abordou a identificação automatizada de artefatos em cintilografia miocárdica por meio da aplicação de inteligência artificial com o objetivo de auxiliar a equipe clínica na triagem inicial da qualidade dos exames. Investigando o desafio imposto pela DAC, uma das principais causas de mortalidade global, este trabalho objetivou melhorar a precisão diagnóstica e a interpretação de imagens de CPM, fundamentais para o tratamento e a prevenção da DAC. A proposta combina a arquitetura nnU-Net para segmentação supervisionada com um modelo de regressão para estimativa da interferência diagnóstica, sendo avaliada por métricas quantitativas e por validação externa cega com especialistas. Diferentemente de abordagens centradas apenas na acurácia morfológica, o modelo desenvolvido incorpora informações clínicas ao processo de análise, ampliando sua aplicabilidade em cenários reais de cardiologia nuclear.

A hipótese central do estudo, de que seria possível identificar e quantificar automaticamente a interferência de artefatos na análise diagnóstica por meio de IA, foi corroborada. Os resultados demonstraram que a solução proposta apresenta desempenho satisfatório tanto na segmentação do ventrículo esquerdo quanto na detecção de artefatos, com coeficientes de Dice superiores a 87% para o ventrículo e entre 0,300 e 0,940 para as classes de artefatos. A regressão logística obteve AUC de 0,946 na fase de validação e manteve desempenho superior a 0,700 no conjunto de teste, mesmo com diferentes arquiteturas. Na validação externa, observou-se concordância igual ou superior a 60% entre as segmentações geradas automaticamente e aquelas realizadas por especialistas.

Os objetivos do estudo foram atingidos de forma integral. Foi possível desenvolver um modelo treinável com dados rotulados, aplicável à CPM em repouso, que permite identificar interferências significativas entre estruturas críticas e artefatos. A análise quantitativa foi complementada por uma avaliação qualitativa cega, com base em três exames revisados por três especialistas com vasta experiência, o que reforça a consistência prática da solução. A arquitetura 3D-fullres-ResEncL destacou-se entre as avaliadas, apresentando os melhores resultados agregados e confirmando a resiliência do processo de segmentação.

Portanto, conclui-se que a abordagem proposta oferece alternativa promissora para a detecção automatizada de artefatos em exames de CPM, com potencial de integração em fluxos clínicos assistenciais. A incorporação de mecanismos de explicabilidade e a adaptação para ambientes operacionais em tempo real representam direções relevantes para aprimoramentos futuros. A combinação entre desempenho técnico e aplicabilidade prática posiciona esta ferramenta como um recurso viável para apoio à decisão em cardiologia nuclear, especialmente em contextos com elevada demanda diagnóstica ou infraestrutura limitada.

6.1 Contribuição do trabalho

Artigos publicados em revista:

NOGUEIRA, S.A.; LUZ, F.A.B.; CALIXTO, W.P. et al. Artificial intelligence applied in identifying left ventricular walls in myocardial perfusion scintigraphy images: pilot study. Plos One (2024)

Trabalho enviado para Congresso e premiado:

Luz, F.A.B.; Nogueira, S.A.; Camargo, T.F.O.; Oliveira, J.C.S.; Campos Neto, G.C.; Carvalhaes, F.B.F.; dos Santos, P.V.; Rodrigues, M.C.R.; Calixto, W.P. Identification of artifacts in myocardial perfusion scintigraphy images using artificial intelligence. ALASBIMN, México, 2025.

Artigo submetido em revista:

Luz, F.A.B.; Nogueira, S.A.; Camargo, T.F.O.; Oliveira, J.C.S.; Campos Neto, G.C.; Carvalhaes, F.B.F. Tornieri, D.; Calixto, W.P. AI- driven identification of diagnostic artifacts in myocardial perfusion scintigraphy. JACC: Cardiovascular Imaging, vx, nº x, 202x.

REFERÊNCIAS BIBLIOGRÁFICAS

ACT, A. Health insurance portability and accountability act of 1996. **Public law**, v. 104, p. 191, 1996. [43](#), [44](#)

AGOSTINI, D.; MARIE, P.-Y.; BEN-HAIM, S.; ROUZET, F.; SONGY, B.; GIORDANO, A.; GIMELLI, A.; HYAFIL, F.; SCIAGRÀ, R.; BUCERIUS, J. et al. Performance of cardiac cadmium-zinc-telluride gamma camera imaging in coronary artery disease: a review from the cardiovascular committee of the european association of nuclear medicine (eanm). **European journal of nuclear medicine and molecular imaging**, Springer, v. 43, p. 2423–2432, 2016. [39](#)

ALSKAF, E.; DUTTA, U.; SCANNELL, C. M.; CHIRIBIRI, A. Deep learning applications in myocardial perfusion imaging, a systematic review and meta-analysis. **Informatics in Medicine Unlocked**, Elsevier, p. 101055, 2022. [28](#)

ALVARENGA, V. S. F.; SMANIO, P. E. P. Appropriate use of myocardial perfusion scintigraphy criteria for assessing asymptomatic patients with high cardiovascular risk or known coronary disease. **Arq Bras Cardiol: Imagem cardiovasc.**, Arq Bras Cardiol: Imagem cardiovasc., v. 34, n. 3, 2021. [39](#)

ANAGNOSTOPOULOS, C.; NEILL, J.; REYES, E.; PRVULOVICH, E. Myocardial perfusion scintigraphy: technical innovations and evolving clinical applications. **Heart**, BMJ, v. 98, n. 5, p. 353–359, nov 14 2011. ISSN 1355-6037. [27](#)

APOSTOLOPOULOS, I. D.; PAPANDRIANOS, N. I.; FELEKI, A.; MOUSTAKIDIS, S.; PAPAGEORGIOU, E. I. Deep learning-enhanced nuclear medicine spect imaging applied to cardiac studies. **EJNMMI physics**, Springer, v. 10, n. 1, p. 6, 2023. [32](#), [33](#), [82](#)

ARSANJANI, R.; XU, Y.; DEY, D.; FISH, M.; DORBALA, S.; HAYES, S.; BERMAN, D.; GERMANO, G.; SLOMKA, P. Improved Accuracy of Myocardial Perfusion SPECT for the Detection of Coronary Artery Disease Using a Support Vector Machine Algorithm. **Journal of Nuclear Medicine**, Society of Nuclear Medicine, v. 54, n. 4, p. 549–555, mar 12 2013. ISSN 0161-5505. [28](#), [29](#)

ASHBURNER, J.; FRISTON, K. J. Voxel-based morphometry—the methods. **Neuroimage**, Elsevier, v. 11, n. 6, p. 805–821, 2000. [31](#)

- ATHAR, H.; HELLER, G. V. Basic principles of flow tracers. **Nuclear Cardiology: Technical Applications**, McGraw Hill Professional, p. 49, 2008. [37](#), [41](#)
- AYAZ, M.; PASHA, M. F.; ALZHRANI, M. Y.; BUDIARTO, R.; STIAWAN, D. The fast health interoperability resources (fhir) standard: systematic literature review of implementations, applications, challenges and opportunities. **JMIR medical informatics**, JMIR Publications Toronto, Canada, v. 9, n. 7, p. e21929, 2021. [51](#), [55](#)
- BARRAGÁN-MONTERO, A.; JAVAID, U.; VALDÉS, G.; NGUYEN, D.; DESBORDES, P.; MACQ, B.; WILLEMS, S.; VANDEWINCKELE, L.; HOLMSTRÖM, M.; LÖFMAN, F. et al. Artificial intelligence and machine learning for medical imaging: A technology review. **Physica Medica**, Elsevier, v. 83, p. 242–256, 2021. [45](#)
- BASSETT, L. **Introduction to JavaScript object notation: a to-the-point guide to JSON**. [S.l.]: "O'Reilly Media, Inc.", 2015. [53](#), [57](#)
- BECKER, S. H.; ARENSON, R. L. Costs and benefits of picture archiving and communication systems. **Journal of the American Medical Informatics Association**, BMJ Group BMA House, Tavistock Square, London, WC1H 9JR, v. 1, n. 5, p. 361–371, 1994. [43](#)
- BEN-HAIM, S.; KENNEDY, J.; KEIDAR, Z. Novel Cadmium Zinc Telluride Devices for Myocardial Perfusion Imaging—Technological Aspects and Clinical Applications. **Seminars in Nuclear Medicine**, Elsevier BV, v. 46, n. 4, p. 273–285, 7 2016. ISSN 0001-2998. [27](#)
- BERNABE, J. B.; CANOVAS, J. L.; HERNANDEZ-RAMOS, J. L.; MORENO, R. T.; SKARMETA, A. Privacy-preserving solutions for blockchain: Review and challenges. **IEEE Access**, IEEE, v. 7, p. 164908–164940, 2019. [43](#), [44](#)
- BETANCUR, J.; COMMANDEUR, F.; MOTLAGH, M.; SHARIR, T.; EINSTEIN, A. J.; BOKHARI, S.; FISH, M. B.; RUDDY, T. D.; KAUFMANN, P.; SINUSAS, A. J.; MILLER, E. J.; BATEMAN, T. M.; DORBALA, S.; CARLI, M. D.; GERMANO, G.; OTAKI, Y.; TAMARAPPOO, B. K.; DEY, D.; BERMAN, D. S.; SLOMKA, P. J. Deep Learning for Prediction of Obstructive Disease From Fast Myocardial Perfusion SPECT. **JACC: Cardiovascular Imaging**, Elsevier BV, v. 11, n. 11, p. 1654–1663, 11 2018. ISSN 1936-878X. [28](#)

BETANCUR, J.; COMMANDEUR, F.; MOTLAGH, M.; SHARIR, T.;
EINSTEIN, A. J.; BOKHARI, S.; FISH, M. B.; RUDDY, T. D.; KAUFMANN, P.;
SINUSAS, A. J. et al. Deep learning for prediction of obstructive disease from fast
myocardial perfusion spect: a multicenter study. **JACC: Cardiovascular
Imaging**, American College of Cardiology Foundation Washington, DC, v. 11,
n. 11, p. 1654–1663, 2018. [30](#)

BETANCUR, J.; HU, L.-H.; COMMANDEUR, F.; SHARIR, T.; EINSTEIN,
A. J.; FISH, M. B.; RUDDY, T. D.; KAUFMANN, P. A.; SINUSAS, A. J.;
MILLER, E. J.; BATEMAN, T. M.; DORBALA, S.; CARLI, M. D.; GERMANO,
G.; OTAKI, Y.; LIANG, J. X.; TAMARAPPOO, B. K.; DEY, D.; BERMAN,
D. S.; SLOMKA, P. J. Deep Learning Analysis of Upright-Supine High-Efficiency
SPECT Myocardial Perfusion Imaging for Prediction of Obstructive Coronary
Artery Disease: A Multicenter Study. **Journal of Nuclear Medicine**, Society of
Nuclear Medicine, v. 60, n. 5, p. 664–670, sep 27 2018. ISSN 0161-5505. [28](#)

BRAUNSTEIN, M. L. Healthcare in the age of interoperability: the promise of fast
healthcare interoperability resources. **IEEE pulse**, IEEE, v. 9, n. 6, p. 24–27,
2018. [51](#), [55](#)

BUDZYŃSKA, A.; OSIECKI, S.; MAZUREK, A.; PISZCZEK, S.; DZIUK, M.
Feasibility of myocardial perfusion imaging studies in morbidly obese patients with
a cadmium-zinc-telluride cardiac camera. **Nuclear Medicine Review**, v. 22,
n. 1, p. 18–22, 2019. [39](#), [40](#)

BUECHEL, R. R.; PAZHENKOTIL, A. P.; HERZOG, B. A.; HUSMANN, L.;
NKOULOU, R. N.; BURGER, I. A.; VALENTA, I.; WYSS, C. A.; GHADRI, J. R.;
KAUFMANN, P. A. Real-time breath-hold triggering of myocardial perfusion
imaging with a novel cadmium-zinc-telluride detector gamma camera. **European
Journal of Nuclear Medicine and Molecular Imaging**, Springer Science and
Business Media LLC, v. 37, n. 10, p. 1903–1908, jun 2 2010. ISSN 1619-7070. [27](#)

CALIXTO, W. P.; NETO, L. M.; WU, M.; YAMANAKA, K.; MOREIRA, E. da
P. Parameters estimation of a horizontal multilayer soil using genetic algorithm.
IEEE Transactions on Power Delivery, IEEE, v. 25, n. 3, p. 1250–1257, 2010.
[59](#)

CANTONI, V.; GREEN, R.; ACAMPA, W.; ZAMPELLA, E.; ASSANTE, R.;
NAPPI, C.; GAUDIERI, V.; MANNARINO, T.; CUOCOLO, R.; VAIA, E. D. et

al. Diagnostic performance of myocardial perfusion imaging with conventional and czt single-photon emission computed tomography in detecting coronary artery disease: A meta-analysis. **Journal of Nuclear Cardiology**, Springer, v. 28, p. 698–715, 2021. [39](#)

CHATTERJEE, A. R.; STALCUP, S.; SHARMA, A.; SATO, T. S.; GUPTA, P.; LEE, Y. Z.; MALONE, C.; MCBEE, M.; HOTALING, E. L.; KANSAGRA, A. P. Image sharing in radiology—a primer. **Academic radiology**, Elsevier, v. 24, n. 3, p. 286–294, 2017. [43](#), [44](#)

CHEN, X.; ZHOU, B.; XIE, H.; SHI, L.; LIU, H.; HOLLER, W.; LIN, M.; LIU, Y.-H.; MILLER, E. J.; SINUSAS, A. J.; LIU, C. Direct and indirect strategies of deep-learning-based attenuation correction for general purpose and dedicated cardiac SPECT. **European Journal of Nuclear Medicine and Molecular Imaging**, Springer Science and Business Media LLC, v. 49, n. 9, p. 3046–3060, feb 16 2022. ISSN 1619-7070. [27](#)

CICEK, V. C.; BABAOGLU, M.; CINAR, T.; MOHAMED, M. L.; BAGCI, U. A review of prognostic prediction of coronary artery disease patients with myocardial perfusion scintigraphy and artificial intelligence. **European Heart Journal - Cardiovascular Imaging**, Oxford University Press (OUP), v. 25, n. Supplement_1, jun 27 2024. ISSN 2047-2404. [28](#)

D., M.; LESLEE, J. S. Coronary Artery Disease: Diagnostic and Prognostic Models for Reducing Patient Risk. **Journal of Cardiovascular Nursing**, 2006. [27](#)

DAHER, Z.; HAJJDIAB, H. Cloud storage comparative analysis amazon simple storage vs. microsoft azure blob storage. **International Journal of Machine Learning and Computing**, v. 8, n. 1, p. 85–9, 2018. [43](#), [44](#)

DAVID, K.; SHISHIR, G.; SHAILEN, S.; RUSHI, P.; SOHUM, S.; MARCO, F.; SEAN, H. K.; JONATHAN, H.; NOAH, B.; JAY, T.; MITCHELL, B.; MADELINE, S.; DAVID, E. W. Risk Stratification Using Cardiac Imaging: A Comprehensive Review. **EMJ Radiology**, 2024. [27](#)

DEY, D.; SLOMKA, P. J.; LEESON, P.; COMANICIU, D.; SHRESTHA, S.; SENGUPTA, P. P.; MARWICK, T. H. Artificial Intelligence in Cardiovascular Imaging. **Journal of the American College of Cardiology**, Elsevier BV, v. 73, n. 11, p. 1317–1335, 3 2019. ISSN 0735-1097. [28](#)

- DITTRICH, R. P.; CHOWDHURY, Y. S. Nuclear medicine artifacts. 2021. [40](#)
- DOUKAS, C.; PLIAKAS, T.; MAGLOGIANNIS, I. Mobile healthcare information management utilizing cloud computing and android os. **Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference**, v. 2010, p. 1037–40, 08 2010. [43](#), [44](#)
- DOWSLEY, T.; AL-MALLAH, M.; ANANTHASUBRAMANIAM, K.; DWIVEDI, G.; MCARDLE, B.; CHOW, B. J. The Role of Noninvasive Imaging in Coronary Artery Disease Detection, Prognosis, and Clinical Decision Making. **Canadian Journal of Cardiology**, Elsevier BV, v. 29, n. 3, p. 285–296, 3 2013. ISSN 0828-282X. [27](#)
- DU, G.; CAO, X.; LIANG, J.; CHEN, X.; ZHAN, Y. Medical image segmentation based on u-net: A review. **Journal of Imaging Science & Technology**, v. 64, n. 2, 2020. [45](#)
- E., D. How to detect and avoid myocardial perfusion SPECT artifacts. **Journal of Nuclear Medicine**, 1994. [28](#)
- EISENBERG, E.; MILLER, R. J.; HU, L.-H.; RIOS, R.; BETANCUR, J.; AZADANI, P.; HAN, D.; SHARIR, T.; EINSTEIN, A. J.; BOKHARI, S. et al. Diagnostic safety of a machine learning-based automatic patient selection algorithm for stress-only myocardial perfusion spect. **Journal of Nuclear Cardiology**, Elsevier, v. 29, n. 5, p. 2295–2307, 2022. [81](#)
- EL-TARABOULSI, J.; CABRERA, C. P.; RONEY, C.; AUNG, N. Deep neural network architectures for cardiac image segmentation. **Artificial Intelligence in the Life Sciences**, Elsevier, p. 100083, 2023. [31](#), [33](#)
- FATHALA, A. Myocardial perfusion scintigraphy: techniques, interpretation, indications and reporting. **Annals of Saudi medicine**, King Faisal Specialist Hospital & Research Centre, v. 31, n. 6, p. 625–634, 2011. [36](#), [38](#)
- FIECHTER, M.; GEBHARD, C.; FUCHS, T. A.; GHADRI, J. R.; STEHLI, J.; KAZAKAUSKAITE, E.; HERZOG, B. A.; PAZHENKOTTIL, A. P.; GAEMPERLI, O.; KAUFMANN, P. A. Cadmium-zinc-telluride myocardial perfusion imaging in obese patients. **Journal of Nuclear Medicine**, Soc Nuclear Med, v. 53, n. 9, p. 1401–1406, 2012. [40](#)

FREYMANN, J. B.; KIRBY, J. S.; PERRY, J. H.; CLUNIE, D. A.; JAFFE, C. C. Image data sharing for biomedical research—meeting hipaa requirements for de-identification. **Journal of digital imaging**, Springer, v. 25, n. 1, p. 14–24, 2012. [51](#)

General Electric Company Healthcare Ltd. **Discovery NM 530c DICOM Conformance Statement**. Revision 5. United Kingdom, 2017. This document outlines the DICOM conformance for the Discovery NM 530c, including specifics on the DICOM implementation and compliance for nuclear medicine imaging. [51](#)

GLASSNER, A. S. Space subdivision for fast ray tracing. **IEEE Computer Graphics and applications**, IEEE, v. 4, n. 10, p. 15–24, 1984. [31](#)

GOMEZ, J.; DOUKKY, R. Artificial Intelligence in Nuclear Cardiology. **Journal of Nuclear Medicine**, Society of Nuclear Medicine, v. 60, n. 8, p. 1042–1043, mar 29 2019. ISSN 0161-5505. [28](#), [29](#)

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge, Massachusetts: MIT press, 2016. (Adaptive Computation and Machine Learning series). ISBN 9780262035613. [53](#), [57](#)

HAGIO, T.; POITRASSON-RIVIÈRE, A.; MOODY, J. B.; RENAUD, J. M.; ARIDA-MOODY, L.; SHAH, R. V.; FICARO, E. P.; MURTHY, V. L. “virtual” attenuation correction: improving stress myocardial perfusion spect imaging using deep learning. **European Journal of Nuclear Medicine and Molecular Imaging**, Springer, v. 49, n. 9, p. 3140–3149, 2022. [31](#)

HAH, H.; GOLDIN, D. S. How clinicians perceive artificial intelligence–assisted technologies in diagnostic decision making: Mixed methods approach. **Journal of Medical Internet Research**, JMIR Publications Toronto, Canada, v. 23, n. 12, p. e33540, 2021. [45](#)

HANSON, M. A.; FAREED, M. T.; ARGENIO, S. L.; AGUNWAMBA, A. O.; HANSON, T. R. Coronary artery disease. **Primary Care: Clinics in Office Practice**, Elsevier, v. 40, n. 1, p. 1–16, 2013. [35](#), [36](#)

HARRIS, P. A.; TAYLOR, R.; MINOR, B. L.; ELLIOTT, V.; FERNANDEZ, M.; O’NEAL, L.; MCLEOD, L.; DELACQUA, G.; DELACQUA, F.; KIRBY, J. et al. The redcap consortium: building an international community of software platform

partners. **Journal of biomedical informatics**, Elsevier, v. 95, p. 103208, 2019. [52](#), [55](#)

HARRIS, P. A.; TAYLOR, R.; THIELKE, R.; PAYNE, J.; GONZALEZ, N.; CONDE, J. G. Research electronic data capture (redcap)—a metadata-driven methodology and workflow process for providing translational research informatics support. **Journal of biomedical informatics**, Elsevier, v. 42, n. 2, p. 377–381, 2009. [52](#), [55](#)

HEINLE, I.; SIRAJ, Q. H. Artefacts and pitfalls in myocardial perfusion imaging. In: **Integrating cardiology for nuclear medicine physicians: A guide to nuclear medicine physicians**. Berlim: Springer, 2009. p. 325–342. [40](#), [41](#)

HIRONAKA, F. H.; ONO, C. R.; BUCHPIGUEL, C. A.; SAPIENZA, M. T.; LIMA, M. S. et al. **Medicina nuclear: princípios e aplicações** [2. [S.l.]: Atheneu, 2017. [37](#)

HU, L.-H.; BETANCUR, J.; SHARIR, T.; EINSTEIN, A. J.; BOKHARI, S.; FISH, M. B.; RUDDY, T. D.; KAUFMANN, P. A.; SINUSAS, A. J.; MILLER, E. J.; BATEMAN, T. M.; DORBALA, S.; CARLI, M. D.; GERMANO, G.; COMMANDEUR, F.; LIANG, J. X.; OTAKI, Y.; TAMARAPPOO, B. K.; DEY, D.; BERMAN, D. S.; SLOMKA, P. J. Machine learning predicts per-vessel early coronary revascularization after fast myocardial perfusion SPECT: results from multicentre REFINE SPECT registry. **European Heart Journal - Cardiovascular Imaging**, Oxford University Press (OUP), v. 21, n. 5, p. 549–559, jul 16 2019. ISSN 2047-2404. [28](#)

HUANG, L.; MIRON, A.; HONE, K.; LI, Y. Segmenting medical images: From UNet to Res-UNet and nnUNet. In: IEEE. **2024 IEEE 37th International Symposium on Computer-Based Medical Systems (CBMS)**. [S.l.], 2024. p. 483–489. [81](#)

HYAFIL, F.; GIMELLI, A.; SLART, R. H.; GEORGOULIAS, P.; RISCHPLER, C.; LUBBERINK, M.; SCIAGRA, R.; BUCERIUS, J.; AGOSTINI, D.; VERBERNE, H. J. Eanm procedural guidelines for myocardial perfusion scintigraphy using cardiac-centered gamma cameras. **European Journal of Hybrid Imaging**, SpringerOpen, v. 3, n. 1, p. 1–27, 2019. [36](#), [37](#)

- IOANNIS, D. A.; N., P.; TRIFON, S.; D., A. Automatic characterization of myocardial perfusion imaging polar maps employing deep learning and data augmentation. **Hellenic journal of nuclear medicine**, 2020. [29](#)
- ISENSEE, F.; JAEGER, P. F.; KOHL, S. A.; PETERSEN, J.; MAIER-HEIN, K. H. nnu-net: a self-configuring method for deep learning-based biomedical image segmentation. **Nature methods**, Nature Publishing Group, v. 18, n. 2, p. 203–211, 2021. [45](#), [53](#), [57](#)
- ISENSEE, F.; JÄGER, P. F.; FULL, P. M.; VOLLMUTH, P.; MAIER-HEIN, K. H. nnu-net for brain tumor segmentation. In: SPRINGER. **Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 6th International Workshop, BrainLes 2020, Held in Conjunction with MICCAI 2020**. Lima, Peru, 2021. p. 118–132. [45](#), [46](#), [47](#)
- ISENSEE, F.; ULRICH, C.; WALD, T.; MAIER-HEIN, K. H. Extending nnU-Net is all you need. **Bildverarbeitung für die Medizin**, arXiv, 2022. [57](#)
- JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An introduction to statistical learning**. Berlin: Springer, 2013. v. 112. [54](#)
- KAPUCU, Ö. L.; NOBILI, F.; VARRONE, A.; BOOIJ, J.; BORGHT, T. V.; NÅGREN, K.; DARCOURT, J.; TATSCH, K.; LAERE, K. J. V. Eanm procedure guideline for brain perfusion spect using 99m tc-labelled radiopharmaceuticals, version 2. **European journal of nuclear medicine and molecular imaging**, Springer, v. 36, p. 2093–2102, 2009. [30](#)
- KHASAWNEH, H.; PATRA, A.; RAJAMOHAN, N.; SUMAN, G.; KLUG, J.; MAJUMDER, S.; CHARI, S. T.; KORFIATIS, P.; GOENKA, A. H. Volumetric pancreas segmentation on computed tomography: Accuracy and efficiency of a convolutional neural network versus manual segmentation in 3d slicer in the context of interreader variability of expert radiologists. **Journal of computer assisted tomography**, LWW, v. 46, n. 6, p. 841–847, 2022. [52](#)
- KIKUCHI, A.; WADA, N.; KAWAKAMI, T.; NAKAJIMA, K.; YONEYAMA, H. A myocardial extraction method using deep learning for 99mtc myocardial perfusion spect images: A basic study to reduce the effects of extra-myocardial activity. **Computers in Biology and Medicine**, Elsevier, v. 141, p. 105164, 2022. [27](#), [31](#), [33](#)

LAROBINA, M.; MURINO, L. Medical image file formats. **Journal of digital imaging**, Springer, v. 27, p. 200–206, 2014. [43](#)

LI, D. L.; KRONENBERG, M. W. Myocardial perfusion and viability imaging in coronary artery disease: clinical value in diagnosis, prognosis, and therapeutic guidance. **The American Journal of Medicine**, Elsevier, v. 134, n. 8, p. 968–975, 2021. [27](#), [37](#), [39](#)

LIN, A.; KOLOSSVÁRY, M.; MOTWANI, M.; IŠGUM, I.; MAUROVICH-HORVAT, P.; SLOMKA, P. J.; DEY, D. Artificial Intelligence in Cardiovascular Imaging for Risk Stratification in Coronary Artery Disease. **Radiology: Cardiothoracic Imaging**, Radiological Society of North America (RSNA), v. 3, n. 1, p. e200512, feb 1 2021. ISSN 2638-6135. [27](#), [28](#)

LIU, H.; WU, J.; MILLER, E. J.; LIU, C.; YAQIANG; LIU; LIU, Y.-H. Diagnostic accuracy of stress-only myocardial perfusion spect improved by deep learning. **European Journal of Nuclear Medicine and Molecular Imaging**, Springer, v. 48, p. 2793–2800, 2021. [30](#), [81](#)

LIU, J.; YANG, Y.; WERNICK, M. N.; PRETORIUS, P. H.; KING, M. A. Deep learning with noisetonoise training for denoising in SPECT myocardial perfusion imaging. **Medical Physics**, Wiley, v. 48, n. 1, p. 156–168, nov 23 2020. ISSN 0094-2405. [29](#)

LIU, J.; YANG, Y.; WERNICK, M. N.; PRETORIUS, P. H.; SLOMKA, P. J.; KING, M. A. Improving detection accuracy of perfusion defect in standard dose spect-myocardial perfusion imaging by deep-learning denoising. **Journal of Nuclear Cardiology**, Springer, p. 1–10, 2021. [28](#), [29](#)

MALAKAR, A. K.; CHOUDHURY, D.; HALDER, B.; PAUL, P.; UDDIN, A.; CHAKRABORTY, S. A review on coronary artery disease, its risk factors, and therapeutics. **Journal of cellular physiology**, Wiley Online Library, v. 234, n. 10, p. 16812–16823, 2019. [35](#), [36](#)

MANN, A.; WILLIAMS, J. Considerations for stress testing performed in conjunction with myocardial perfusion imaging. **Journal of Nuclear Medicine Technology**, Soc Nuclear Med, v. 48, n. 2, p. 114–121, 2020. [39](#)

MARQUES, G.; AGARWAL, D.; DÍEZ, I. De la T. Automated medical diagnosis of covid-19 through efficientnet convolutional neural network. **Applied soft computing**, Elsevier, v. 96, p. 106691, 2020. [45](#)

MAZOUZI, S.; GUESSOUM, Z. A fast and fully distributed method for region-based image segmentation: Fast distributed region-based image segmentation. **Journal of Real-Time Image Processing**, Springer, v. 18, n. 3, p. 793–806, 2021. [58](#)

MITITELU, R.; STANCIU, S.; MAZILU, C.; MITITELU, T.; MITITELU, L.; GHERMAN, A. M. Common artifacts in myocardial perfusion imaging. **Romanian Journal of**, v. 124, n. 4, p. 567, 2021. [27](#), [28](#), [40](#)

NEUFELD, P. M. et al. Stress echocardiography in the diagnosis of coronary artery disease: A systematic review. **Brazilian Journal of Health & Biomedical Sciences**, v. 20, n. 1, 2021. [35](#), [36](#)

NOGUEIRA, S. A.; LUZ, F. A. B.; CAMARGO, T. F. O.; OLIVEIRA, J. C. S.; NETO, G. C. C.; CARVALHAES, F. B. F.; REIS, M. R. C.; SANTOS, P. V.; MENDES, G. S.; LOUREIRO, R. M. et al. Artificial intelligence applied in identifying left ventricular walls in myocardial perfusion scintigraphy images: pilot study. **Plos one**, Public Library of Science San Francisco, CA USA, v. 20, n. 1, p. e0312257, 2025. [27](#), [56](#), [82](#)

NOLAN, L. L. et al. **The influence of low-dose CT attenuation correction on artefacts of myocardial SPECT images for nuclear medicine studies.** Tese (Doutorado) — Cape Peninsula University of Technology, 2021. [36](#), [37](#), [39](#), [40](#)

NUDI, F.; ISKANDRIAN, A. E.; SCHILLACI, O.; PERUZZI, M.; FRATI, G.; BIONDI-ZOCCAI, G. Diagnostic Accuracy of Myocardial Perfusion Imaging With CZT Technology. **JACC: Cardiovascular Imaging**, Elsevier BV, v. 10, n. 7, p. 787–794, 7 2017. ISSN 1936-878X. [27](#)

OLIA, N. A.; KAMALI-ASL, A.; TABRIZI, S. H.; GERAMIFAR, P.; SHEIKHZADEH, P.; FARZANEFAR, S.; ARABI, H.; ZAIDI, H. Deep learning-based denoising of low-dose spect myocardial perfusion images: quantitative assessment and clinical performance. **European journal of nuclear medicine and molecular imaging**, Springer, p. 1–15, 2022. [30](#), [33](#)

ORA, M.; GAMBHIR, S. Myocardial perfusion imaging: a brief review of nuclear and nonnuclear techniques and comparative evaluation of recent advances. **Indian journal of nuclear medicine: IJNM: the official journal of the Society of Nuclear Medicine, India**, Wolters Kluwer–Medknow Publications, v. 34, n. 4, p. 263, 2019. [36](#)

OTAKI, Y.; SINGH, A.; KAVANAGH, P.; MILLER, R. J.; PAREKH, T.; TAMARAPPOO, B. K.; SHARIR, T.; EINSTEIN, A. J.; FISH, M. B.; RUDDY, T. D.; KAUFMANN, P. A.; SINUSAS, A. J.; MILLER, E. J.; BATEMAN, T. M.; DORBALA, S.; CARLI, M. D.; CADET, S.; LIANG, J. X.; DEY, D.; BERMAN, D. S.; SLOMKA, P. J. Clinical Deployment of Explainable Artificial Intelligence of SPECT for Diagnosis of Coronary Artery Disease. **JACC: Cardiovascular Imaging**, Elsevier BV, v. 15, n. 6, p. 1091–1102, 6 2022. ISSN 1936-878X. [28](#)

PANTANOWITZ, L.; SHARMA, A.; CARTER, A. B.; KURC, T.; SUSSMAN, A.; SALTZ, J. Twenty years of digital pathology: an overview of the road travelled, what is on the horizon, and the emergence of vendor-neutral archives. **Journal of pathology informatics**, Elsevier, v. 9, n. 1, p. 40, 2018. [43](#)

PAPANDRIANOS, N.; PAPAGEORGIOU, E. Automatic Diagnosis of Coronary Artery Disease in SPECT Myocardial Perfusion Imaging Employing Deep Learning. **Applied Sciences**, MDPI AG, v. 11, n. 14, p. 6362, jul 9 2021. ISSN 2076-3417. [28](#)

PAPANDRIANOS, N. I.; APOSTOLOPOULOS, I. D.; FELEKI, A.; MOUSTAKIDIS, S.; KOKKINOS, K.; PAPAGEORGIOU, E. I. Ai-based classification algorithms in SPECT myocardial perfusion imaging for cardiovascular diagnosis: a review. **Nuclear Medicine Communications**, Ovid Technologies (Wolters Kluwer Health), v. 44, n. 1, p. 1–11, nov 15 2022. ISSN 0143-3636. [28](#)

PATEL, J. J.; ALZHRANI, T. Myocardial perfusion scan. 2019. [36](#), [37](#), [38](#)

PINTER, C.; LASSO, A.; WANG, A.; JAFFRAY, D.; FICHTINGER, G. Slicerrt: radiation therapy research toolkit for 3d slicer. **Medical physics**, Wiley Online Library, v. 39, n. 10, p. 6332–6338, 2012. [53](#), [55](#)

PRASAD, M.; SLOMKA, P. J.; FISH, M.; KAVANAGH, P.; GERLACH, J.; HAYES, S.; BERMAN, D. S.; GERMANO, G. Improved Quantification and Normal Limits for Myocardial Perfusion Stress–Rest Change. **Journal of**

Nuclear Medicine, Society of Nuclear Medicine, v. 51, n. 2, p. 204–209, 2 2010. ISSN 0161-5505. [29](#)

PRETORIUS, P. H.; LIU, J.; KALLURI, K.; KING, M. A.; AUER, B.; LINDSAY, C.; KONIK, A.; YANG, Y.; WERNICK, M. N. Assessment of Defect Detection in Post-Filtering and Deep Learning Denoising Strategies for Reduced Dose Myocardial Perfusion SPECT Employing Human and Polar Map Observers. In: **IEEE. 2021 IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC)**. [S.l.], 2021. p. 1–3. [29](#)

R., A.; A., K.; M., R.; MOLOUD, A.; N., S.; DAVOOD, S.; F., K.; A., S.; S., N.; M., P.; ANDREW, M. B.; R., B.; R., P.; S., K.; RUYAN, T.; U., R. A. Coronary artery disease detection using artificial intelligence techniques: A survey of trends, geographical differences and diagnostic features 1991-2020. **Comput. Biol. Medicine**, 2020. [27](#)

R., A.; MOLOUD, A.; M., R.; A., K.; P., K.; F., K.; S., N.; N., S.; N., S.; U., R. A.; USHA, R. A.; USHA, R. A. Machine learning-based coronary artery disease diagnosis: A comprehensive review. **Comput. Biol. Medicine**, 2019. [27](#)

RAMON, A. J.; YANG, Y.; PRETORIUS, P. H.; JOHNSON, K. L.; KING, M. A.; WERNICK, M. N. Improving Diagnostic Accuracy in Low-Dose SPECT Myocardial Perfusion Imaging With Convolutional Denoising Networks. **IEEE Transactions on Medical Imaging**, Institute of Electrical and Electronics Engineers (IEEE), v. 39, n. 9, p. 2893–2903, 9 2020. ISSN 0278-0062. [29](#)

RAMOS, S. M. O.; GLAVAM, A. P.; BRITO, A. S. de; KUBO, T. T. A.; TUKAMOTO, G.; SAMPAIO, D. d. C. P.; SÁ, L. V. de. Prone myocardial perfusion imaging and breast attenuation: A phantom study. **Current Medical Imaging**, Bentham Science Publishers, v. 16, n. 1, p. 70–79, 2020. [39](#), [40](#)

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, proceedings, part III 18, 2015**. Munich, Germany, 2015. p. 234–241. [45](#)

S., B.; A., M. Artifacts and pitfalls in myocardial perfusion imaging. **Journal of Nuclear Medicine Technology**, 2006. [27](#)

SALKICA, N.; SEHIC, A.; JULARDZIJA, F.; COROVIC, H. Elimination of the artifacts on myocardial perfusion single photon emission tomography (spect) scintigraphy-new prospects. **International Journal of Medical Reviews and Case Reports**, Bulgarian Association of Young Surgeons, v. 3, n. 11, p. 748–748, 2020. [40](#)

SHAHJEHAN, R. D.; BHUTTA, B. S. Coronary artery disease. In: **StatPearls [Internet]**. [S.l.]: StatPearls Publishing, 2022. [35](#)

SHANBHAG, A. D.; MILLER, R. J.; PIESZKO, K.; LEMLEY, M.; KAVANAGH, P.; FEHER, A.; MILLER, E. J.; SINUSAS, A. J.; KAUFMANN, P. A.; HAN, D.; HUANG, C.; LIANG, J. X.; BERMAN, D. S.; DEY, D.; SLOMKA, P. J. Deep learning-based attenuation correction improves diagnostic accuracy of cardiac SPECT. **Journal of Nuclear Medicine**, Society of Nuclear Medicine, v. 64, n. 3, p. 472–478, sep 22 2022. ISSN 0161-5505. [82](#)

SIDDIQUE, N.; PAHEDING, S.; ELKIN, C. P.; DEVABHAKTUNI, V. U-net and its variants for medical image segmentation: A review of theory and applications. **Ieee Access**, IEEE, v. 9, p. 82031–82057, 2021. [46](#), [47](#)

SIOCHI, R. A.; BALTER, P.; BLOCH, C. D.; SANTANAM, L.; BLODGETT, K.; CURRAN, B. H.; ENGELSMAN, M.; FENG, W.; MECHALAKOS, J.; PAVORD, D. et al. Report of task group 201 of the american association of physicists in medicine: quality management of external beam therapy data transfer. **Medical physics**, Wiley Online Library, v. 48, n. 6, p. e86–e114, 2021. [43](#)

SLOMKA, P. J.; BETANCUR, J.; LIANG, J. X.; OTAKI, Y.; HU, L.-H.; SHARIR, T.; DORBALA, S.; CARLI, M. D.; FISH, M. B.; RUDDY, T. D. et al. Rationale and design of the registry of fast myocardial perfusion imaging with next generation spect (refine spect). **Journal of Nuclear Cardiology**, Elsevier, v. 27, n. 3, p. 1010–1021, 2020. [81](#)

SOHLBERG, A.; KANGASMAA, T.; CONSTABLE, C.; TIKKAKOSKI, A. Comparison of deep learning-based denoising methods in cardiac spect. **EJNMMI physics**, Springer, v. 10, n. 1, p. 9, 2023. [29](#)

STROK, A.; NOVAK, M. D.; SALOBIR, B. G.; ZALETEL, K.; STALC, M. The impact of number of steps on gastrointestinal activity-related artifacts in myocardial perfusion scintigraphy. 2023. [36](#), [41](#)

TANG, L. H.; HANKA, R.; IP, H. H. A review of intelligent content-based indexing and browsing of medical images. **Health Informatics Journal**, Sage Publications Sage CA: Thousand Oaks, CA, v. 5, n. 1, p. 40–49, 1999. [43](#)

VELAZQUEZ, E. R.; PARMAR, C.; JERMOUMI, M.; MAK, R. H.; BAARDWIJK, A. V.; FENNESSY, F. M.; LEWIS, J. H.; RUYSSCHER, D. D.; KIKINIS, R.; LAMBIN, P. et al. Volumetric ct-based segmentation of nsccl using 3d-slicer. **Scientific reports**, Nature Publishing Group UK London, v. 3, n. 1, p. 3529, 2013. [53](#), [55](#)

VERDIER, M.; DEVERDUN, J.; CHAMPFLEUR, N. M. de; DUFFAU, H.; LAM, P.; SANTOS, T. D.; TROALEN, T.; MARÉCHAL, B.; HUELNHAGEN, T.; BARS, E. L. Evaluation of a nnu-net type automated clinical volumetric tumor segmentation tool for diffuse low-grade glioma follow-up. **Journal of Neuroradiology**, Elsevier, 2023. [45](#), [46](#)

WANG, C.; REN, K.; LOU, W.; LI, J. Toward publicly auditable secure cloud data storage services. **IEEE network**, IEEE, v. 24, n. 4, p. 19–24, 2010. [29](#), [43](#), [44](#)

WEBERLING, L. D.; LOSSNITZER, D.; FREY, N.; ANDRÉ, F. Coronary Computed Tomography vs. Cardiac Magnetic Resonance Imaging in the Evaluation of Coronary Artery Disease. **Diagnostics**, MDPI AG, v. 13, n. 1, p. 125, dec 30 2022. ISSN 2075-4418. [27](#)

WOŹNIAK, M.; WIECZOREK, M.; SIŁKA, J. Bilstm deep neural network model for imbalanced medical data of iot systems. **Future Generation Computer Systems**, Elsevier, v. 141, p. 489–499, 2023. [45](#)

YANG, J.; SHI, L.; WANG, R.; MILLER, E. J.; SINUSAS, A. J.; LIU, C.; GULLBERG, G. T.; SEO, Y. Direct attenuation correction using deep learning for cardiac spect: A feasibility study. **Journal of Nuclear Medicine**, Soc Nuclear Med, v. 62, n. 11, p. 1645–1652, 2021. [31](#), [33](#)

ZHANG, L.; LABELLE, W.; UNBERATH, M.; CHEN, H.; HU, J.; LI, G.; DREIZIN, D. A vendor-agnostic, pacs integrated, and dicom-compatible software-server pipeline for testing segmentation algorithms within the clinical radiology workflow. 2023. [43](#), [44](#)

ZHU, Y.; CHEN, L.; LU, W.; GONG, Y.; WANG, X. The application of the nnU-Net-based automatic segmentation model in assisting carotid artery stenosis

and carotid atherosclerotic plaque evaluation. **Frontiers in Physiology**, Frontiers Media SA, v. 13, dec 6 2022. ISSN 1664-042X. [31](#), [33](#), [81](#)

