



UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ARTES, CIÊNCIAS E HUMANIDADES
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS DE INFORMAÇÃO

PEDRO HENRIQUE MORAIS DELMONDES

**Sistemas de auxílio ao diagnóstico de cardiomiopatias: uma abordagem
baseada em descritores *multi-slice* e *multi-frame***

São Paulo

2023

PEDRO HENRIQUE MORAIS DELMONDES

**Sistemas de auxílio ao diagnóstico de cardiomiopatias: uma abordagem
baseada em descritores *multi-slice* e *multi-frame***

Dissertação apresentada à Escola de Artes, Ciências e Humanidades da Universidade de São Paulo para obtenção do título de Mestre em Ciências pelo Programa de Pós-graduação em Sistemas de Informação.

Área de concentração: Metodologia e Técnicas da Computação

Versão corrigida contendo as alterações solicitadas pela comissão julgadora em 12 de dezembro de 2022. A versão original encontra-se em acervo reservado na Biblioteca da EACH-USP e na Biblioteca Digital de Teses e Dissertações da USP (BDTD), de acordo com a Resolução CoPGr 6018, de 13 de outubro de 2011.

Orientador: Profa. Dra. Fátima de Lourdes dos Santos Nunes Marques

São Paulo

2023

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Ficha catalográfica elaborada pela Biblioteca da Escola de Artes, Ciências e Humanidades,
com os dados inseridos pelo(a) autor(a)
Brenda Fontes Malheiros de Castro CRB 8-7012; Sandra Tokarevicz CRB 8-4936

Morais Delmondes, Pedro Henrique
Sistemas de auxílio ao diagnóstico de
cardiomiopatias: uma abordagem baseada em
descritores multi-slice e multi-frame / Pedro
Henrique Moraes Delmondes; orientadora, Fátima de
Lourdes dos Santos Nunes Marques. -- São Paulo,
2022.

81 p: il.

Dissertacao (Mestrado em Ciencias) - Programa de
Pós-Graduação em Sistemas de Informação, Escola de
Artes, Ciências e Humanidades, Universidade de São
Paulo, 2022.

Versão corrigida

1. recuperação por conteúdo. 2. ressonância
magnética. 3. cardiologia. 4. cardiomiopatia. 5.
descritores. I. Marques, Fátima de Lourdes dos
Santos Nunes, orient. II. Título.

Dissertação de autoria de Pedro Henrique Morais Delmondes, sob o título “**Sistemas de auxílio ao diagnóstico de cardiomiopatias: uma abordagem baseada em descritores *multi-slice* e *multi-frame***”, apresentada à Escola de Artes, Ciências e Humanidades da Universidade de São Paulo, para obtenção do título de Mestre em Ciências pelo Programa de Pós-graduação em Sistemas de Informação, na área de concentração Metodologia e Técnicas da Computação, aprovada em 12 de dezembro de 2022 pela comissão julgadora constituída pelos doutores:

Profa. Dra. Fátima de Lourdes dos Santos Nunes
Marques
Universidade de São Paulo
Presidente

Prof. Dr. Cléber Gimenez Corrêa
Universidade Federal Tecnológica do Paraná

Prof. Dr. Carlos Eduardo Rochitte
Universidade de São Paulo

Agradecimentos

Agradeço a meu pai, minha mãe, irmã e namorada pelo amor e apoio incondicional que serviram de base para tudo que construí até aqui.

A todos os professores que já tive na escola e na universidade. Cada aula, ensinamento, conselho e momento de descontração ajudaram a formar a pessoa que sou hoje.

Em especial, gostaria de agradecer à professora Fátima, com quem nos últimos 10 anos tive a oportunidade de aprender, trocar experiências e crescer pessoal e profissionalmente.

Agradeço à Escola de Artes Ciências e Humanidades da Universidade de São Paulo, e ao Programa de Pós-graduação em Sistemas de Informação pela formação e pelo apoio financeiro que obtive para a revisão de inglês do artigo “A systematic review of multi-slice and multi-frame descriptors in cardiac MRI exams”, fruto deste trabalho.

“Olhem de novo esse ponto. É aqui, é a nossa casa, somos nós. Nele, todos a quem ama, todos a quem conhece, qualquer um sobre quem você ouviu falar, cada ser humano que já existiu, viveram as suas vidas. O conjunto da nossa alegria e nosso sofrimento, milhares de religiões, ideologias e doutrinas econômicas confiantes, cada caçador e coletor, cada herói e covarde, cada criador e destruidor da civilização, cada rei e camponês, cada jovem casal de namorados, cada mãe e pai, criança cheia de esperança, inventor e explorador, cada professor de ética, cada político corrupto, cada “superestrela”, cada “líder supremo”, cada santo e pecador na história da nossa espécie viveu ali – em um grão de pó suspenso num raio de sol. [...] Não há, talvez, melhor demonstração da tola presunção humana do que esta imagem distante do nosso minúsculo mundo. Para mim, destaca a nossa responsabilidade de sermos mais amáveis uns com os outros, e para preservarmos e protegermos o “pálido ponto azul”, o único lar que conhecemos até hoje.”

(Carl Sagan)

Resumo

DELMONDES, Pedro Henrique Morais. **Sistemas de auxílio ao diagnóstico de cardiomiopatias: uma abordagem baseada em descritores *multi-slice* e *multi-frame*** 2023. 81 f. Dissertação (Mestrado em Ciências) – Escola de Artes, Ciências e Humanidades, Universidade de São Paulo, São Paulo, 2022.

Nas últimas décadas, o aumento populacional e a manutenção das doenças cardíacas como as maiores causadoras de mortes no mundo têm aumentado a demanda por exames de Ressonância Magnética cardíaca, que são úteis para auxiliar o diagnóstico médico de cardiomiopatias. Um grande aliado dos profissionais da saúde são sistemas de auxílio ao diagnóstico capazes de quantificar as características de um exame de Ressonância Magnética cardíaca, poupando trabalho manual e fornecendo uma “segunda opinião” quanto ao diagnóstico de um paciente. A partir de uma revisão sistemática, constatou-se que diversos descritores que quantificam características do ventrículo esquerdo cardíaco em um exame de Ressonância Magnética cardíaca têm sido implementados nas últimas décadas, porém, uma lacuna foi encontrada no âmbito de utilizar de descritores que consideram todos os *slices* de um exame ao longo de todo o ciclo cardíaco. Dessa forma, esse trabalho objetivou definir e implementar descritores para quantificar a função cardíaca do ventrículo esquerdo considerando todos os *slices* ao longo do ciclo cardíaco. Para atingir esse objetivo, foi realizada uma revisão sistemática, definição e segmentação de uma base de dados, elaboração e implementação de descritores e medidas de similaridade, execução de técnicas de redução de dimensionalidade, testes e avaliação dos resultados. Verificou-se que os métodos propostos foram efetivos na identificação de pacientes sem anomalia e com cardiomiopatia hipertrófica, ao considerar um conjunto de dados estratificado por sexo e idade, obtendo valores de Área sob a Curva do gráfico de Precisão *versus* Revocação de 0,83 e 0,69, respectivamente. Ao se considerar o conjunto de dados não estratificado, foram obtidos valores de AUC de 0,48 e 0,50, respectivamente para pacientes sem anomalia e com cardiomiopatia hipertrófica. Espera-se que esse trabalho contribua para a área da Medicina e da Computação, servindo de base para novos estudos em sistemas de auxílio ao diagnóstico que utilizem ou desenvolvam descritores cardíacos que considerem todos os *slices* de um exame de Ressonância Magnética.

Palavras-chaves: Ressonância Magnética. Ventrículo Esquerdo. Descritor. Sistemas de Auxílio ao Diagnóstico.

Abstract

DELMONDES, Pedro Henrique Morais. **Computer-aided diagnosis of cardiomyopathies: an approach based on multi-slice and multi-frame feature descriptors**. 2023. 81 p. Dissertation (Master of Science) – School of Arts, Sciences and Humanities, University of São Paulo, São Paulo, 2022.

In the last decades, population growth and the continuity of cardiac diseases as the top cause of death worldwide has increased the demand for magnetic resonance exams, as they are useful to aid medical diagnosis on cardiomyopathies. A great ally to medical professionals are Computer-Aided Diagnosis systems that are capable to quantify a cardiac magnetic resonance exam characteristics, saving manual workload and providing a “second opinion” regarding a patient’s diagnosis. From the results of a systematic review, it was found that several feature descriptors that aim to quantify the characteristics of the heart’s left ventricle in a magnetic resonance exam have been implemented in the last decades, however, a gap has been identified, as no descriptors that consider all the slices of an exam along the cardiac cycle exist. In order to close this gap, this work aimed to define and implement descriptors to quantify the left ventricle’s cardiac function considering all slices across the cardiac cycle. In order to achieve this objective, a systematic review was performed, a data set was developed and segmented, descriptors and similarity measures were designed and implemented, dimensionality reduction techniques, testing and evaluation were performed. It was verified that the proposed methods were effective in identifying normal patients and patients with hypertrophic cardiomyopathy when a database stratified by gender and age was used, achieving Area Under the Curve values of 0,83 e 0,69, respectively. When the data set with no stratification was considered, the AUC values obtained were 0,48 e 0,50, respectively to normal patients and patients with hypertrophic cardiomyopathy. It is expected that this work will contribute to the Medicine and Computing areas by serving as a foundation to new studies in Computer-Aided Diagnosis systems that use or develop cardiac descriptors that consider all slices of a Magnetic Resonance exam.

Keywords: Magnetic resonance. Left Ventricle. Descriptor. Computer-Aided Diagnosis.

Lista de figuras

Figura 1 – <i>Slice</i> extraído de um exame de Ressonância Magnética cardíaca. O círculo verde externo indica o epicárdio e o círculo vermelho interno indica o endocárdio; o miocárdio é a região muscular mais escura, compreendida entre essas duas estruturas.	20
Figura 2 – Anatomia simplificada do coração humano. Figura originalmente inspirada em Marieb <i>et al.</i> (2014) e extraída de Ribeiro (2020).	20
Figura 3 – <i>Slices</i> extraídos de três exames de Ressonância Magnética cardíaca ilustrando exemplos de exames cardíacos diagnosticados como: (a) normal; (b) cardiomiopatia hipertrófica e (c) cardiomiopatia dilatada.	21
Figura 4 – Diagrama ilustrando como as diferentes imagens obtidas em um exame de <i>cine-MRI</i> cardíaco se organizam em <i>slices</i> e <i>frames</i>	23
Figura 5 – <i>Slices</i> de exames de Ressonância Magnética cardíaca extraídos de Radau <i>et al.</i> (2009) ilustrando os diferentes planos anatômicos do coração: (a) eixo curto, (b) eixo longo de quatro câmaras e (c) eixo longo de duas câmaras.	23
Figura 6 – Exemplo de gráfico gerado pelas curvas de Precisão <i>versus</i> Revocação.	26
Figura 7 – Exemplo de Matriz de Distâncias.	27
Figura 8 – Evolução da quantidade de artigos recuperados, aceitos e rejeitados após cada passo.	31
Figura 9 – Frequência de cada Objetivo Clínico e Objetivo Técnico	34
Figura 10 – Frequência de cada descritor nos artigos incluídos (Legenda de cores: Azul = Forma; Amarelo = Textura; Vermelho = Movimento; Verde = Clínico)	37
Figura 11 – Quantidade de artigos aceitos considerando a categoria de descritor e os objetivos técnico e clínico	38
Figura 12 – Frequência de cada técnica nos artigos incluídos (Legenda de cores: Azul = Processamento de Imagem; Amarelo = IA Clássica; Vermelho = Aprendizado Profundo; Verde = Modelos Deformáveis).	39
Figura 13 – Fluxo geral do processo executado no presente projeto de pesquisa.	47

Figura 14 – Interface do sistema <i>Segment</i> com um exame de Ressonância Magnética aberto.	50
Figura 15 – Ferramenta de segmentação semi-automática do ventrículo esquerdo.	50
Figura 16 – Exame com epicárdio (em verde) e endocárdio (em vermelho) segmentados em sete slices do exame.	51
Figura 17 – Fluxo de cálculo do descritor C3, no qual a média do deslocamento de cada <i>slice</i> é obtida.	54
Figura 18 – Fluxo de cálculo do descritor C16, no qual a média do volume de cada <i>slice</i> no fim da diástole é obtida.	54
Figura 19 – Exemplos de limitações apresentadas ao utilizar o método semi-automático de segmentação. (a) <i>slice</i> basal apresenta segmentação anatomicamente incorreta; (b) imagem segmentada em um <i>frame</i> de sístole onde é possível perceber que o contorno do endocárdio em vermelho não acompanha o movimento do endocárdio.	57
Figura 20 – Gráfico da curva de Precisão <i>versus</i> Revocação dos pacientes diagnosticados como sem anomalia utilizando um vetor de 15 características. AUC obtida = 0,3981.	59
Figura 21 – Gráfico da curva de Precisão <i>versus</i> Revocação dos pacientes diagnosticados com cardiomiopatia hipertrófica utilizando um vetor de 15 características. AUC obtida = 0,4584.	59
Figura 22 – Gráfico da curva de Precisão <i>versus</i> Revocação dos pacientes diagnosticados com cardiomiopatia dilatada utilizando um vetor de 15 características. AUC obtida = 0,3083.	60
Figura 23 – Gráfico da curva de Precisão <i>versus</i> Revocação dos pacientes diagnosticados como sem anomalia utilizando um vetor de 18 características. AUC obtida = 0,4813.	61
Figura 24 – Gráfico da curva de Precisão <i>versus</i> Revocação dos pacientes diagnosticados com cardiomiopatia hipertrófica utilizando um vetor de 18 características. AUC obtida = 0,5086.	61
Figura 25 – Gráfico da curva de Precisão <i>versus</i> Revocação dos pacientes diagnosticados com cardiomiopatia dilatada utilizando um vetor de 18 características. AUC obtida = 0,3367.	62

Figura 26 – Gráfico da curva de Precisão <i>versus</i> Revocação dos pacientes do grupo G6 diagnosticados como sem anomalia. AUC obtida = 0,86667.	63
Figura 27 – Gráfico da curva de Precisão <i>versus</i> Revocação dos pacientes do grupo G6 diagnosticados com cardiomiopatia hipertrófica. AUC obtida = 0,7871.	64
Figura 28 – Gráfico da curva de Precisão <i>versus</i> Revocação dos pacientes do grupo G6 diagnosticados com cardiomiopatia dilatada. AUC obtida = 0,4462.	64
Figura 29 – Matriz de Distâncias obtida a partir dos resultados de recuperação dos pacientes do grupo G6.	65

Lista de quadros

Quadro 1 – Critérios de inclusão e exclusão utilizados no processo de seleção de estudos durante a revisão sistemática de literatura (I: Inclusão; E: Exclusão).	30
Quadro 2 – Dados gerais dos estudos incluídos na revisão sistemática da literatura (OT = Objetivo Técnico; OC = Objetivo Clínico; PI = Processamento de Imagem).	33
Quadro 3 – Descritores Extraídos	36
Quadro 4 – Métricas de avaliação usadas nas abordagens apresentadas nos artigos aceitos. Legenda: X = Parâmetros Estimados; Y = Parâmetros extraídos manualmente; VP = Verdadeiro Positivo, FP = Falso Positivo, VN = Verdadeiro Negativo, FN = Falso Negativo; R = Soma dos postos; n: Tamanho da amostra; cov = Covariância; σ = Desvio padrão; μ = Média	42
Quadro 5 – Descritores desenvolvidos que compõem o vetor de características de cada exame.	53

Lista de tabelas

Tabela 1 – Bases de dados públicas usadas pelas abordagens apresentadas nos artigos aceitos e detalhes quantitativos por paciente.	41
Tabela 2 – Medidas de AUC obtidas em cada um dos conjuntos de pacientes estratificados.	58
Tabela 3 – Medidas de AUC obtidas em cada um dos conjuntos de pacientes estratificados.	63
Tabela 4 – Medidas de AUC obtidas em cada um dos experimentos.	66

Sumário

1	Introdução	15
1.1	<i>Motivação</i>	16
1.2	<i>Objetivo e justificativa</i>	17
1.3	<i>Organização do documento</i>	18
2	Conceitos fundamentais	19
2.1	<i>Anatomia cardíaca</i>	19
2.2	<i>Cardiomiopatias</i>	19
2.3	<i>Ressonância Magnética</i>	21
2.4	<i>Sistemas de Auxílio ao Diagnóstico</i>	22
2.5	<i>Seleção de Características</i>	25
2.6	<i>Avaliação de sistemas CBIR</i>	26
2.7	<i>Considerações finais do capítulo</i>	27
3	Revisão bibliográfica	29
3.1	<i>Planejamento e protocolo</i>	29
3.2	<i>Seleção de estudos e extração de dados</i>	29
3.3	<i>Análise dos resultados</i>	31
3.3.1	<i>Análise geral</i>	32
3.3.2	<i>Descritores</i>	35
3.3.3	<i>Técnicas</i>	37
3.3.4	<i>Bases de dados públicas</i>	40
3.3.5	<i>Avaliação</i>	41
3.4	<i>Discussão e oportunidades</i>	43
3.5	<i>Considerações finais do capítulo</i>	46
4	Materiais e Métodos	47
4.1	<i>Conjunto de dados e segmentação</i>	49
4.2	<i>Descritores</i>	51
4.3	<i>Algoritmo Relief</i>	52
4.4	<i>Avaliação das técnicas</i>	54

4.5	<i>Considerações finais do capítulo</i>	55
5	Resultados e Discussões	56
5.1	<i>Segmentação</i>	56
5.2	<i>Seleção de Características</i>	57
5.3	<i>Recuperação de exames utilizando vetor de 15 características</i>	58
5.4	<i>Recuperação de exames utilizando 18 características</i>	60
5.5	<i>Recuperação de exames utilizando 18 características com estratificação da base de dados</i>	62
5.6	<i>Análise geral do desempenho das abordagens</i>	66
5.7	<i>Considerações finais do capítulo</i>	67
6	Conclusão	68
6.1	<i>Trabalhos futuros</i>	68
6.2	<i>Contribuições</i>	69
	REFERÊNCIAS	71
	APÊNDICES	78
	Apêndice A – Protocolo de revisão bibliográfica sistemática .	79

1 Introdução

A Medicina é uma das áreas que mais tem se beneficiado do advento da tecnologia. Com o auxílio desta, tem sido possível realizar exames de medicina diagnóstica baseados em imagem, como a Radiografia, Tomografia Computadorizada (TC) e a Ressonância Magnética Nuclear (MRI).

Exames de imagem, diferentemente de outros exames clínicos, geram dados complexos que demandam uma maior capacidade computacional para seu processamento e armazenamento. Além disso, com a evolução dos equipamentos de diagnóstico, imagens cada vez mais precisas e conseqüentemente com maior volume de dados estão sendo geradas, demandando sistemas cada vez mais eficientes para gerenciar, armazenar e processar tais imagens (ISSA; BYERS; DAKSHANAMURTHY, 2014).

Nesse contexto, conforme indicado por Giger (2018), a incorporação de sistemas de auxílio ao diagnóstico (CAD - *Computer-Aided Diagnosis*) na rotina de médicos durante as últimas décadas tem sido crescente, uma vez que esses sistemas podem ser úteis para auxiliar no armazenamento, recuperação e análise das imagens médicas de um paciente de forma eficiente. Sistemas CAD são elaborados para fornecer uma “segunda opinião” ao ponto de vista do médico, agindo de forma complementar à habilidade humana de modo a atingir um diagnóstico mais preciso de um paciente (DOI, 2007).

Sistemas CAD podem ser utilizados para auxiliar na tarefa de segmentação de imagens como visto em (NASR-ESFAHANI *et al.*, 2018); para reconstruir a superfície de um objeto tridimensional (3D) a partir do conjunto de *slices* como em (TUFVESSON *et al.*, 2015); recuperar imagens similares de exames já diagnosticados em sistemas de recuperação de imagens por conteúdo (CBIR - *Content-Based Image Retrieval*) (CHETHAN; BHANDARKAR, 2020); e também para classificar automaticamente exames quanto a existência ou ausência de uma determinada doença (SARMIENTO; PICO; MARTINEZ, 2018). Sistemas que realizam recuperação por conteúdo ou classificação automática de exames possuem uma etapa essencial em seu *pipeline* de execução: a etapa de extração de características. Essa etapa analisa e processa as imagens a fim de quantificar suas características intrínsecas e tornar diferentes exames comparáveis entre si.

Segundo a ORGANIZAÇÃO MUNDIAL DA SAÚDE (2020) (OMS), doenças cardíacas ou cardiopatias têm liderado o *ranking* de causas de mortalidade no mundo

durante as últimas décadas e um dos maiores aliados no diagnóstico de cardiopatias são os exames de diagnóstico por imagem como a MRI e TC. Esses fatores fazem da área de Cardiologia uma das maiores interessadas no uso de sistemas CAD.

Na Cardiologia, um tipo específico de exame de Ressonância Magnética denominado (*cine-MRI - cine-Magnetic Resonance Imaging*) é muito utilizado para diagnosticar doenças que afetam o fluxo sanguíneo dentro do coração, como as cardiomiopatias (FRIEDRICH *et al.*, 2009). Esse tipo de exame considera não apenas a dimensão espacial, representada no conjunto de *slices*, mas também a dimensão temporal, representada na variação dos *slices* ao longo do ciclo cardíaco (*frames*).

O presente projeto de pesquisa se faz necessário ao considerar que a qualidade da “segunda opinião” fornecida pelo sistema CAD com base em CBIR está diretamente relacionada à qualidade e da representatividade das características extraídas da imagem. Este projeto visou o desenvolvimento de técnicas de extração de características (descritores) que considerem todo o conjunto de imagens geradas em um exame do tipo *cine-MRI*, gerando assim características robustas, que considerem tanto a dimensão espacial quanto a temporal.

1.1 Motivação

A quantidade de dados gerados e armazenados no mundo vem aumentando massivamente no mundo inteiro. Em um estudo recente, a *International Data Corporation* estimou que em 2020, cerca de 40 *zetabytes* de informação seriam gerados e segundo Dash *et al.* (2019) dados médicos seguem essa tendência. Há também um crescente interesse da sociedade no desenvolvimento de formas eficientes de coletar e processar tal tipo de informação, uma vez que ela é útil para adquirir conhecimento sobre doenças, melhorar a qualidade de diagnósticos e criar ações preventivas. A construção e a utilização de sistemas computacionais eficientes nos processos de coleta e processamento de dados médicos é crucial para a redução de custos, especialmente em um cenário em que a população mundial, de forma geral, está vivendo cada vez mais tempo e conseqüentemente precisando de mais cuidados médicos ao longo da vida.

Em geral, descritores em sistemas CAD são desenvolvidos com intuito de analisar o conjunto de *slices* em um determinado momento do ciclo cardíaco (*frame*) como o fim

da diástole (MURALA; WU, 2014; AMAN; YAO; SUMMERS, 2010). Ou ainda, com o intuito de extrair de características de objetos 3D reconstruídos a partir dos *slices* como em Bergamasco, Rochitte e Nunes (2018), Delmondes, Bergamasco e Nunes (2015), obtendo uma visão completa do coração em um instante do ciclo cardíaco. Uma outra abordagem utilizada é a de descritores que analisam todas as imagens de um mesmo *slice* ao longo do ciclo cardíaco, possibilitando a análise de como um determinado *slice* se movimenta durante a sístole e a diástole. Alguns problemas nessas abordagens são conhecidos: a extração de características de cada *slice* de um exame exige muito tempo de processamento e a extração de características de modelos 3D, apesar de mais rápida, pode ser menos eficaz, devido à perda de informação durante o processo de reconstrução do modelo 3D.

Uma abordagem ainda pouco explorada na literatura é a de utilizar descritores que considerem o conjunto de *slices* (*multi-slice*) e *frames* (*multi-frame*) de um exame de *cine-MRI* e comparar os descritores desses exames assim obtidos por meio de medidas de similaridade.

Dessa forma, a hipótese a ser validada nesse trabalho é a de que sistemas CAD que utilizam descritores *multi-slice* e *multi-frame* de um exame de *cine-MRI* e que realizam a comparação desses exames por meio de medidas de similaridade, possuem índices de precisão e revocação próximos ou melhores do que os de sistemas CAD que extraem características de um conjunto de *slices* no mesmo instante do ciclo cardíaco, que consideram *slice* individualmente ao longo do ciclo cardíaco ou ainda, que extraem características de modelos 3D.

1.2 Objetivo e justificativa

O objetivo geral desse projeto é propor e desenvolver um modelo de sistema CAD baseado em CBIR que, na etapa de extração de características, leve em consideração o conjunto completo de imagens de um exame *cine-MRI* cardíaco. Os modelos propostos neste trabalho devem ser capazes de produzir resultados próximos ou melhores do que implementações prévias de descritores obtidas em Bergamasco, Rochitte e Nunes (2018), Delmondes, Bergamasco e Nunes (2015) e Bergamasco (2013).

Para atingir o objetivo geral desse trabalho, os seguintes objetivos específicos devem ser cumpridos:

- definir e implementar descritores do tipo *multi-slice* e *multi-frame*;
- selecionar e implementar medidas de similaridade a fim de comparar os diferentes vetores de características gerados;
- selecionar e implementar métricas de avaliação entre os resultados obtidos por esse trabalho e outros realizados previamente.

Caso seja comprovado que essa abordagem para definir e implementar descritores de sistemas CAD seja eficiente quanto ao auxílio ao diagnóstico de cardiomiopatias, outros sistemas CAD poderão ser aperfeiçoados integrando esse tipo de abordagem. Além disso, ao se verificar a viabilidade de descritores *multi-slice* e *multi-frame*, novos estudos referentes a extratores desse mesmo tipo poderão ser desenvolvidos e testados com diferentes métodos de comparação, seja por AM ou por medidas de similaridade.

1.3 Organização do documento

Além deste capítulo introdutório, o restante deste documento está organizado da seguinte maneira: no capítulo 2, conceitos básicos fundamentais para o entendimento do projeto são apresentados; uma revisão sistemática da literatura a respeito de descritores que consideram o conjunto total de imagens em um exame de Ressonância Magnética cardíaca foi realizada, e seu protocolo e resultados são apresentados no capítulo 3; o capítulo 4 detalha os métodos e descritores propostos, os detalhes do conjunto de dados e das métricas de avaliação utilizados neste trabalho; os resultados obtidos neste trabalho de pesquisa são apresentados e discutidos no capítulo 5; por fim, no capítulo 6 a conclusão e possíveis trabalhos futuros são apresentados.

2 Conceitos fundamentais

Neste capítulo são apresentados conceitos relacionados ao tema de pesquisa, fundamentais para o entendimento do presente projeto. Na seção 2.1 é apresentada a anatomia do coração humano. Na seção 2.2 as cardiomiopatias, doenças comumente diagnosticadas por meio de exames radiológicos, são descritas; um desses exames é o exame de Ressonância Magnética, detalhado na seção 2.3. Por fim, o processo de extração de características a partir de imagens médicas é detalhado na seção 2.4.

2.1 Anatomia cardíaca

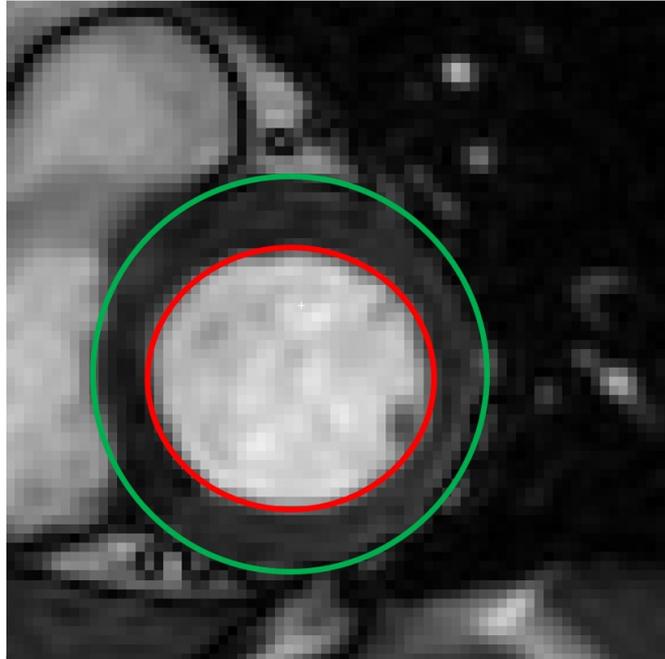
O coração é o órgão responsável pelo bombeamento do sangue para o corpo por meio dos vasos sanguíneos (HALL; HALL, 2020). O coração humano é revestido por uma estrutura denominada parede cardíaca, que é composta por três camadas: epicárdio, a mais externa; miocárdio, a intermediária; e endocárdio, a mais interna (figura 1). O miocárdio, especificamente, é o músculo responsável pelos movimentos de contração (sístole) e relaxamento (diástole) cardíacos, que compõem o ciclo cardíaco e causam o bombeamento sanguíneo (HALL; HALL, 2020).

Dentro da parede cardíaca, existem quatro cavidades: átrio esquerdo, átrio direito, ventrículo esquerdo e ventrículo direito. Durante o ciclo cardíaco, o sangue venoso (rico em gás carbônico) é recebido no átrio direito do coração por meio das veias cavas e repassado ao ventrículo direito de onde é bombeado para os pulmões através da artéria pulmonar. Dentro dos pulmões acontecem trocas gasosas e o sangue venoso se torna sangue arterial (rico em oxigênio) e retorna ao átrio esquerdo do coração por meio da veia pulmonar. O sangue arterial é repassado do átrio esquerdo para o ventrículo esquerdo, de onde é bombeado para o restante do corpo através da artéria aorta (HALL; HALL, 2020). A figura 2 ilustra a anatomia cardíaca de forma simplificada.

2.2 Cardiomiopatias

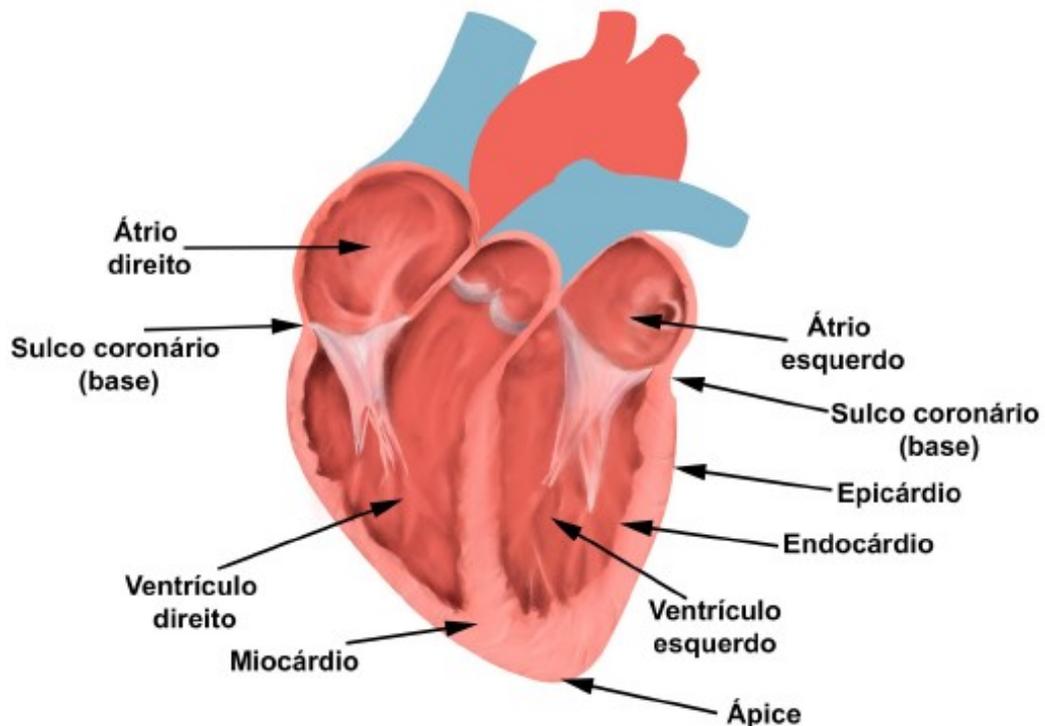
As cardiomiopatias são um grupo de doenças cardíacas cujo principal sintoma é a deformação morfológica de estruturas cardíacas, como o miocárdio e o ventrículo

Figura 1 – *Slice* extraído de um exame de Ressonância Magnética cardíaca. O círculo verde externo indica o epicárdio e o círculo vermelho interno indica o endocárdio; o miocárdio é a região muscular mais escura, compreendida entre essas duas estruturas.



Fonte – Adaptado de Imagens cedidas pelo InCor, 2021

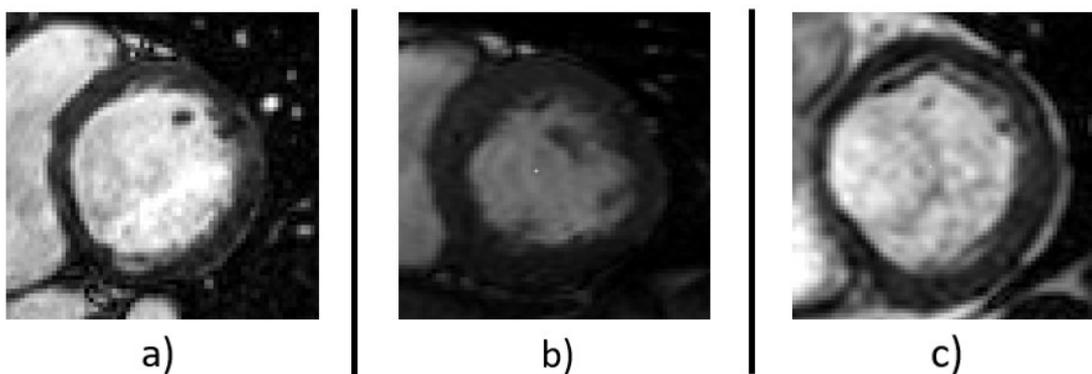
Figura 2 – Anatomia simplificada do coração humano. Figura originalmente inspirada em [Marieb et al. \(2014\)](#) e extraída de [Ribeiro \(2020\)](#).



Fonte – [Ribeiro \(2020\)](#)

esquerdo. Esse tipo de doença é comumente detectado por exames de eletrocardiograma e ecocardiograma mas, em casos complexos, é necessária a realização de um exame de Ressonância Magnética para auxiliar o seu diagnóstico (ALBANESI; MANES, 1998). Dentre os tipos mais comuns de cardiomiopatias, pode-se destacar três: cardiomiopatia dilatada, que causa aumento das cavidades cardíacas, sendo a mais frequente a do ventrículo esquerdo; cardiomiopatia hipertrófica, que causa o espessamento da parede ventricular; e a cardiomiopatia restritiva que compromete o enchimento ventricular durante a diástole. As figuras 3a), 3b) e 3c) mostram respectivamente um *slice* de exame de Ressonância Magnética de um paciente diagnosticado como normal, com cardiomiopatia hipertrófica e cardiomiopatia dilatada, respectivamente.

Figura 3 – *Slices* extraídos de três exames de Ressonância Magnética cardíaca ilustrando exemplos de exames cardíacos diagnosticados como: (a) normal; (b) cardiomiopatia hipertrófica e (c) cardiomiopatia dilatada.



Fonte – Imagens cedidas pelo InCor, 2021

2.3 Ressonância Magnética

A Ressonância Magnética é um tipo de exame radiológico que auxilia o diagnóstico por imagem de diversas doenças, inclusive de doenças cardíacas como cardiomiopatias, insuficiência cardíaca e isquemia.

A execução do exame pode ser dividida em três partes segundo Júnior e Yamashita (2001): alinhamento, excitação e detecção de radiofrequência. Na fase de alinhamento o aparelho de Ressonância Magnética emite um intenso campo magnético que alinha o próton presente no núcleo de átomos de hidrogênio da estrutura examinada (elemento abundante

em estruturas biológicas). Em seguida, durante a fase de excitação, ondas de radiofrequência são emitidas do aparelho de Ressonância Magnética em direção à estrutura examinada, e parte da energia dessas ondas é absorvida pelos átomos de hidrogênio, tornando-os instáveis. Conforme os átomos de hidrogênio retornam à estabilidade, os mesmos emitem ondas eletromagnéticas de radiofrequência que são capturadas pelo aparelho de Ressonância Magnética e transmitidas a um computador responsável por interpretar os sinais e gerar a imagem correspondente.

Um exame de Ressonância Magnética gera um número variável de imagens da estrutura corporal analisada; esse número é influenciado pela especificação do aparelho utilizado e também pelo protocolo utilizado no exame (MCROBBIE *et al.*, 2004). No contexto cardíaco, denominam-se *slices* as imagens de diferentes recortes do coração em um mesmo instante do ciclo cardíaco e *frames* as imagens de um mesmo recorte do coração através de todo o ciclo cardíaco (BOGAERT *et al.*, 2012). Dessa forma, por conter informação espacial do coração, a análise de um conjunto de *slices* é útil para identificar características morfológicas do coração, enquanto a análise dos diferentes *frames*, por conterem informação temporal, é útil para identificar características de movimento e de fluxo sanguíneo durante o ciclo cardíaco. A figura 4 ilustra um exame de Ressonância Magnética que contém três *slices* (basal, medial e apical) e cinco *frames* (compreendendo o ciclo cardíaco de uma diástole à outra).

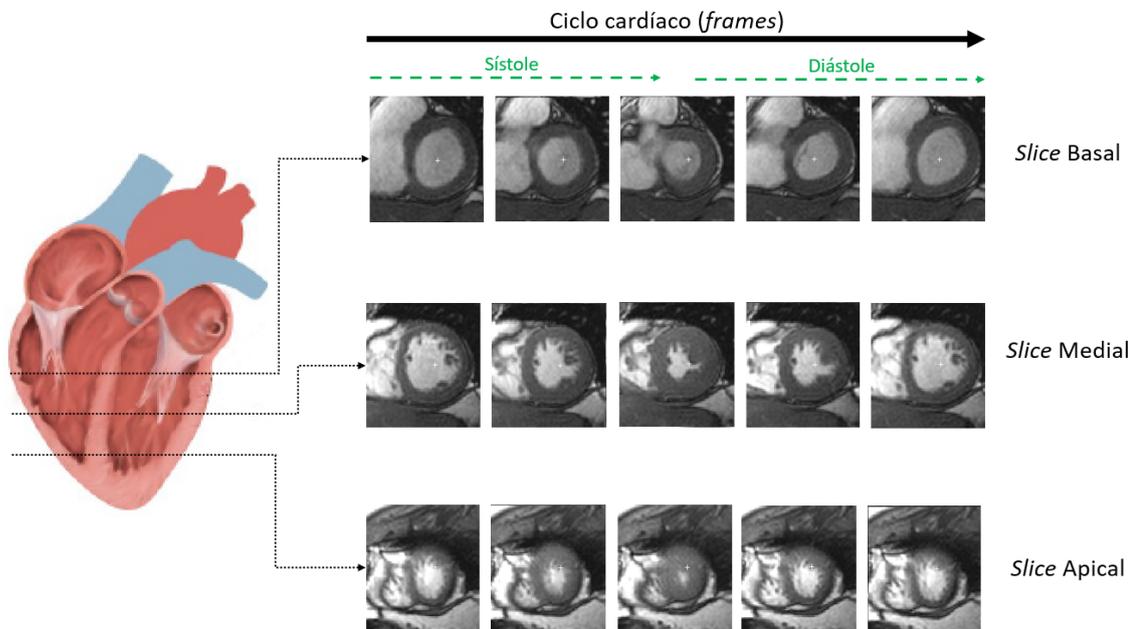
Os *slices* de um exame de Ressonância Magnética cardíaca podem ser obtidos em três diferentes planos anatômicos, denominados eixo curto, eixo longo de quatro câmaras e eixo longo de duas câmaras (NACIF *et al.*, 2010) As figuras 5a), 5b) e 5c) apresentam *slices* de exames nesses três planos, respectivamente.

2.4 Sistemas de Auxílio ao Diagnóstico

Sistemas de auxílio ao diagnóstico (CAD - *Computer-Aided Diagnosis*) são concebidos para prover uma segunda opinião ao médico em relação ao diagnóstico de uma determinada doença, possibilitando um diagnóstico mais preciso e rápido (DOI, 2007).

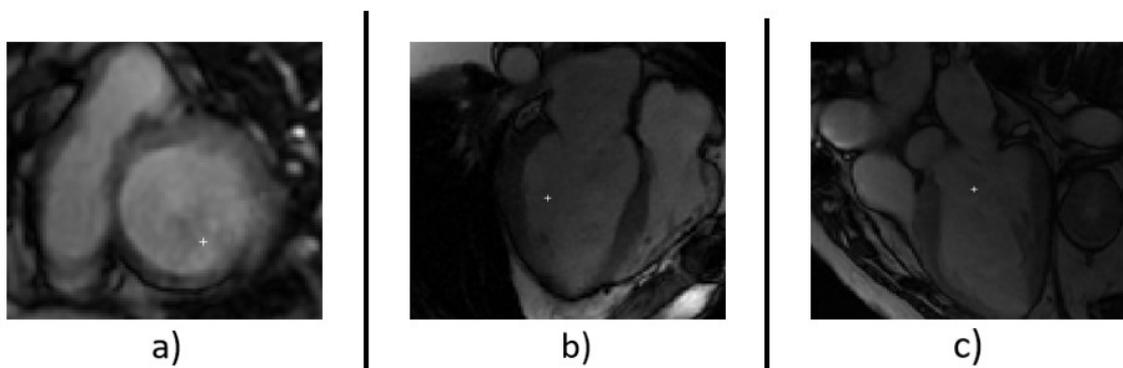
Com a crescente demanda por diagnósticos por imagem, aplicações de sistemas CAD na análise, manipulação e avaliação de imagens médicas têm se popularizado. Tais sistemas podem ser utilizados para identificar regiões de interesse e segmentar exames de imagem

Figura 4 – Diagrama ilustrando como as diferentes imagens obtidas em um exame de *cine-MRI* cardíaco se organizam em *slices* e *frames*.



Fonte – Pedro Henrique Morais Delmondes

Figura 5 – *Slices* de exames de Ressonância Magnética cardíaca extraídos de Radau *et al.* (2009) ilustrando os diferentes planos anatômicos do coração: (a) eixo curto, (b) eixo longo de quatro câmaras e (c) eixo longo de duas câmaras.



Fonte – Radau *et al.* (2009)

como em [Nasr-Esfahani et al. \(2018\)](#), assim como processar imagens bidimensionais para extração de características e até mesmo reconstruir objetos 3D a partir delas como em [Bergamasco, Rochitte e Nunes \(2018\)](#). Esta última abordagem é especialmente útil quando uma composição do diagnóstico pode se beneficiar de informações de volume e forma da estrutura analisada ([TUFVESSON et al., 2015](#)).

Uma das técnicas que podem ser empregadas em sistemas CAD é a de CBIR. Essa técnica consiste em realizar consultas em uma base de dados de imagens utilizando outras imagens como parâmetro de busca, ao invés de palavras-chave, e exibir os resultados de forma ordenada de acordo com sua similaridade em relação ao parâmetro de busca ([TORRES; FALCAO, 2006](#)).

Em sistemas CBIR, a etapa de extração de características é crucial. Nessa etapa, algoritmos são desenvolvidos para extrair características, também chamadas de descritores, que quantificam os elementos intrínsecos de cada imagem, e as armazena em uma estrutura denominada vetor de características ([TORRES; FALCAO, 2006](#)). As características armazenadas, idealmente, devem ser suficientes para identificar similaridades e diferenças entre duas ou mais imagens por meio de um método de comparação.

Dentre os tipos de características extraídas em imagens, podemos destacar características de cor, textura, forma ou ainda, no contexto de imagens médicas cardíacas, características que envolvem a análise de múltiplas imagens (*slices* ou *frames*) como o volume de uma cavidade cardíaca, fração de ejeção ou deslocamento da parede cardíaca durante o ciclo.

Os vetores de características de cada imagem, se possuírem o mesmo tamanho, podem ser comparados por meio de funções de similaridade tal como a função de Distância Euclidiana, representada na equação 1. Nessa equação n indica o tamanho do vetor de características, i indica a posição atual no vetor de características, p e q representam os dois vetores que estão sendo comparados, p_i indica o valor da i -ésima característica do vetor p e q_i indica o valor da i -ésima característica do vetor q .

$$DistânciaEuclidiana = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (1)$$

No caso dos vetores possuírem diferentes tamanhos, trabalhos recentes exploram novos métodos de comparação, como o de [Bergamasco et al. \(2022\)](#), que explora o uso de grafos bipartidos para realizar a recuperação da informação.

Em sistemas mais recentes também é possível observar que técnicas de Inteligência Artificial (IA) têm sido utilizadas para classificar vetores de características, como em [Sarmiento, Pico e Martinez \(2018\)](#) e em [Moreno, Rodriguez e Martínez \(2019\)](#). Dentre as técnicas de IA mais comuns utilizadas para esta tarefa, podem-se destacar os métodos de clusterização, redes neurais e de *Support Vector Machine* (SVM).

2.5 Seleção de Características

Ao se desenvolver múltiplas características para descrever um objeto é comum que certas características sejam mais relevantes para distinguir os objetos de acordo com o problema do que outras. Nesse sentido, é possível que a recuperação por conteúdo possua desempenho diferente de acordo com o subconjunto de características fornecido como entrada. Para que seja possível obter o subconjunto ótimo de características, se faz necessária a execução de algoritmos de seleção de características.

O algoritmo *Relief* apresentado em [Kira e Rendell \(1992\)](#) processa um conjunto de dados rotulados com o valor de sua classe e atribui um peso para cada característica, com valor proporcional à sua relevância na tarefa de diferenciar as classes. Para calcular o peso (W_j) de cada característica (j), o algoritmo seleciona aleatoriamente uma amostra do conjunto de dados (*amostra*) e, para cada instância (n) dessa amostra, identifica quais as outras duas instâncias mais similares a ela: uma da mesma classe (*NearHit*) e outra classe oposta (*NearMiss*). Em seguida, o peso de cada característica é atualizado subtraindo-se do valor atual a soma dos quadrados das diferenças entre o valor da característica n_j e *NearHit_j* e da característica n_j e *NearMiss_j*. Por fim, após calculados todos os pesos, somente características com peso acima de um limiar determinado são selecionadas para serem utilizadas no método em questão.

O algoritmo 1 exemplifica os passos do algoritmo *Relief*:

Algoritmo 1 Seleção de características - *Relief*

- 1: $W_j \leftarrow 0$ para todo j
- 2: **para** $i : 1$ **até** tamanho(amostra) **faca**
- 3: Selecione aleatoriamente uma instância n da amostra
- 4: Identificar a instância *NearHit* e *NearMiss* de n
- 5: **para** $j : 1$ **até** tamanho(W) **faca**
- 6: $W_j \leftarrow W_j - (n_j - \text{NearHit}_j)^2 + (n_j - \text{NearMiss}_j)^2$
- 7: **Fim**

2.6 Avaliação de sistemas CBIR

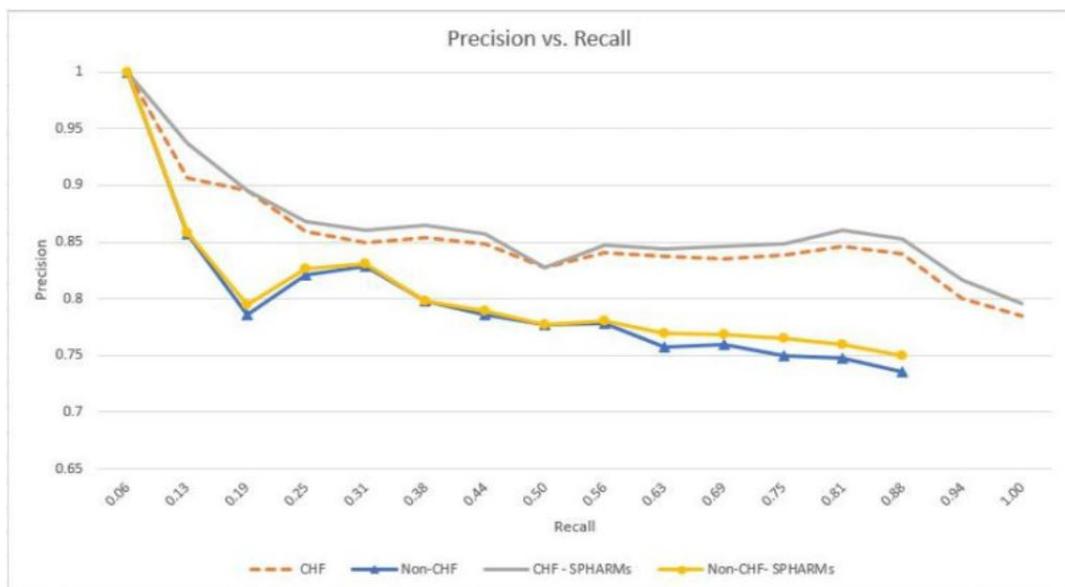
Nas áreas da classificação e recuperação de informação, algumas métricas são consideradas clássicas: Área sob a curva (AUC) do gráfico de Precisão *versus* Revocação e a Matriz de Distâncias.

A métrica de Precisão (Equação 2) indica proporção de elementos relevantes entre todos os que foram recuperados, enquanto a Revocação (Equação 3), possui significado semelhante ao contexto de classificação, indicando a proporção entre os elementos relevantes presentes no banco de dados e as que foram recuperadas. A figura 6 é um exemplo de gráfico que pode ser gerado por curvas de Precisão *versus* Revocação.

$$\text{Precisão} = \frac{\text{ElementosRelevantes} \cap \text{ElementosRecuperados}}{\text{ElementosRecuperados}} \quad (2)$$

$$\text{Revocação} = \frac{\text{ElementosRelevantes} \cap \text{ElementosRecuperados}}{\text{ElementosRelevantes}} \quad (3)$$

Figura 6 – Exemplo de gráfico gerado pelas curvas de Precisão *versus* Revocação.



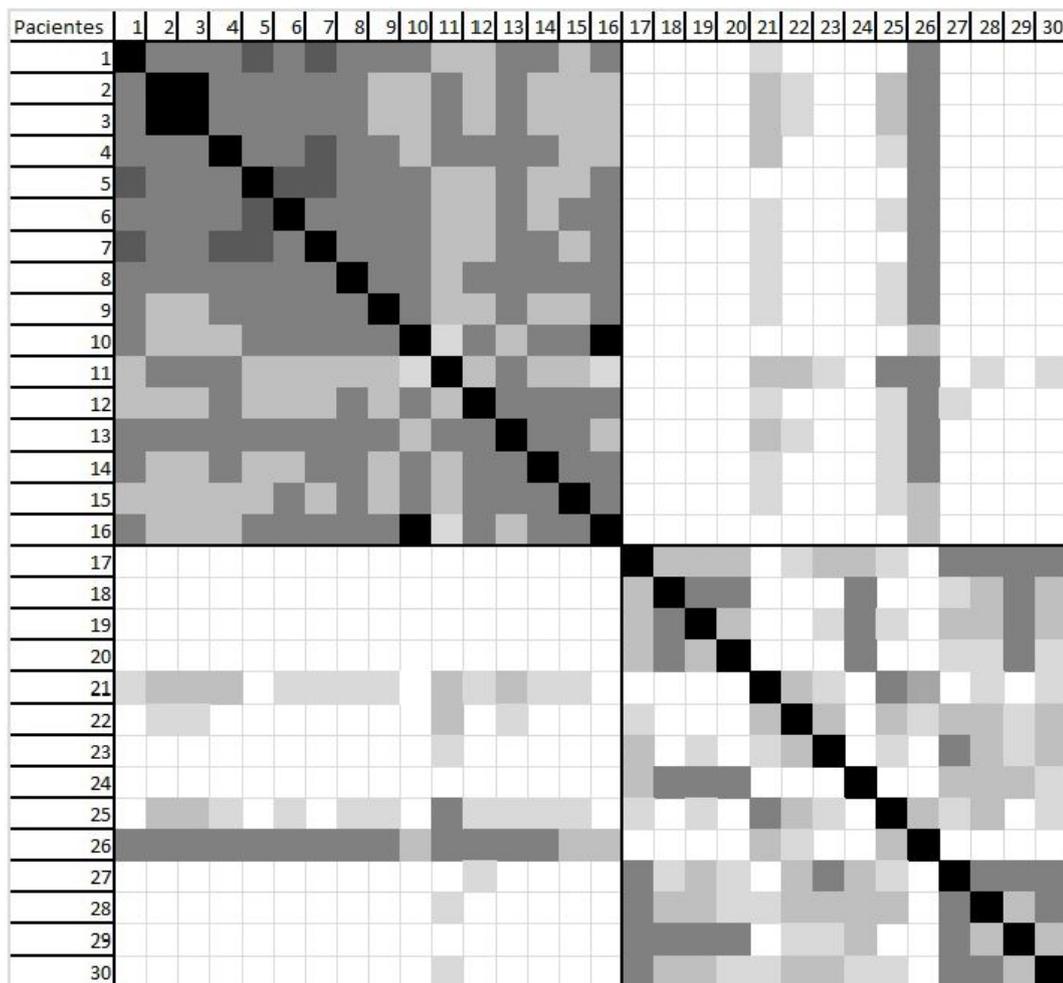
Fonte – Leila Cristina Carneiro Bergamasco, 2018

Uma maneira de comparar o desempenho entre duas técnicas é calculando a AUC da curva de Precisão x Revocação obtida. Na figura 6, por exemplo, apesar da curva "Non-CHF - SPHARMs" estar, de maneira geral, acima da curva "Non-CHF" não é possível aferir quantitativamente, observando o gráfico a diferença de desempenho entre as duas.

Nesse caso, o cálculo da AUC de cada uma das diferentes curvas, auxiliaria a entender de forma precisa o quão melhor é o desempenho de uma técnica em relação a outra.

A Matriz de Distâncias ilustra por meio de uma escala de cores o quão semelhante um caso retornado é daquele fornecido como consulta. Na figura 7, como exemplo, as células foram coloridas de forma que os casos mais similares possuam cor mais escura e as demais cores foram atribuídas de acordo com um critério de intervalo de similaridade. Com essa métrica é possível determinar, por exemplo, a ordem em que casos seriam recuperados da base de dados com base na similaridade com o fornecido como busca.

Figura 7 – Exemplo de Matriz de Distâncias.



Fonte – Pedro Henrique Morais Delmondes, 2022

2.7 Considerações finais do capítulo

Neste capítulo foram apresentados os principais conceitos da anatomia cardíaca, alguns tipos de cardiomiopatia e como os exames de Ressonância Magnética e ferramentas

de auxílio ao diagnóstico, como os sistemas CBIR, podem auxiliar na detecção dessas anomalias. Foram apresentadas também técnicas de redução de dimensionalidade, que podem contribuir no desempenho de um sistema CBIR, e as métricas que são capazes de avaliar o desempenho de diferentes sistemas de forma padronizada.

No próximo capítulo, é apresentada a revisão sistemática realizada neste projeto. Essa revisão visou identificar ferramentas de auxílio ao diagnóstico que utilizavam o conjunto inteiro de imagens geradas em um exame de Ressonância Magnética.

3 Revisão bibliográfica

Neste capítulo uma revisão bibliográfica sistemática realizada para este projeto é detalhada. Serão apresentados o planejamento e protocolo executado, uma análise quantitativa geral dos resultados, bem como um resumo dos descritores, técnicas, bases de dados utilizadas e métricas de avaliação encontrados na literatura. Um artigo contendo os resultados completos dessa revisão sistemática foi publicado [Delmondes e Nunes \(2022\)](#).

3.1 Planejamento e protocolo

Na etapa de planejamento foram definidas inicialmente, as questões de pesquisa a serem respondidas após a análise dos resultados:

- Q1: Quais descritores consideram o conjunto de *slices* e *frames* de um exame de Ressonância Magnética?
- Q2: Esses descritores foram aplicados na identificação de cardiomiopatias?
- Q3: Quais conjuntos de dados foram utilizados para avaliar os descritores?
- Q4: Quais métricas foram utilizadas para medir o desempenho dos descritores?

A partir de uma análise exploratória que encontrou artigos iniciais que deveriam ser incluídos, as seguintes bases de dados científicas foram selecionadas como fontes para pesquisa de trabalhos: *IEEE* ([IEEE, 2020](#)), *ACM* ([ACM, 2020](#)), *PubMed* ([NCBI, 2020](#)), *Science Direct* ([ELSEVIER, 2020a](#)) e *Scopus* ([ELSEVIER, 2020b](#)).

Em seguida, foram definidos os critérios (Quadro 1) para selecionar quais trabalhos seriam incluídos na etapa de análise dessa revisão sistemática. Um determinado trabalho foi incluído quando atendeu a pelo menos um critério de inclusão e não atendeu a qualquer critério de exclusão.

Além das informações aqui apresentadas, outros itens são definidos no protocolo da revisão bibliográfica sistemática disponibilizado no apêndice [A](#).

3.2 Seleção de estudos e extração de dados

Duas buscas foram realizadas em cada base científica: a primeira busca utilizou a *string* de busca (***MRI OR cine-mri OR “magnetic resonance” AND (cardiology***

Quadro 1 – Critérios de inclusão e exclusão utilizados no processo de seleção de estudos durante a revisão sistemática de literatura (I: Inclusão; E: Exclusão).

Critério	Descrição
I1	Trabalhos que apresentam ou aplicam métodos de extração de características do ventrículo esquerdo em exames de Ressonância Magnética cardíaca
I2	Trabalhos que aplicam ou avaliam métodos de extração de características para identificar cardiomiopatias
E1	Trabalhos que não apresentam métodos de extração de características para exames de Ressonância Magnética
E2	Trabalhos que apresentam descritores aplicados em exames que não sejam de Ressonância Magnética
E3	Trabalhos que aplicam métodos de extração de características em estruturas que não sejam o ventrículo esquerdo cardíaco
E4	Trabalhos que apresentam métodos de segmentação de exames de Ressonância Magnética que não utilizam as características da imagem para fazê-la
E5	Trabalhos que apresentam métodos de reconstrução de modelos 3D a partir de exames de Ressonância Magnéticas ou que apresentam métodos de extração de características de modelos 3D
E6	Trabalhos que estão em formato de <i>short paper</i> e ainda sem resultados finais
E7	Trabalhos que realizam extração de características em uma abordagem <i>black-box</i>

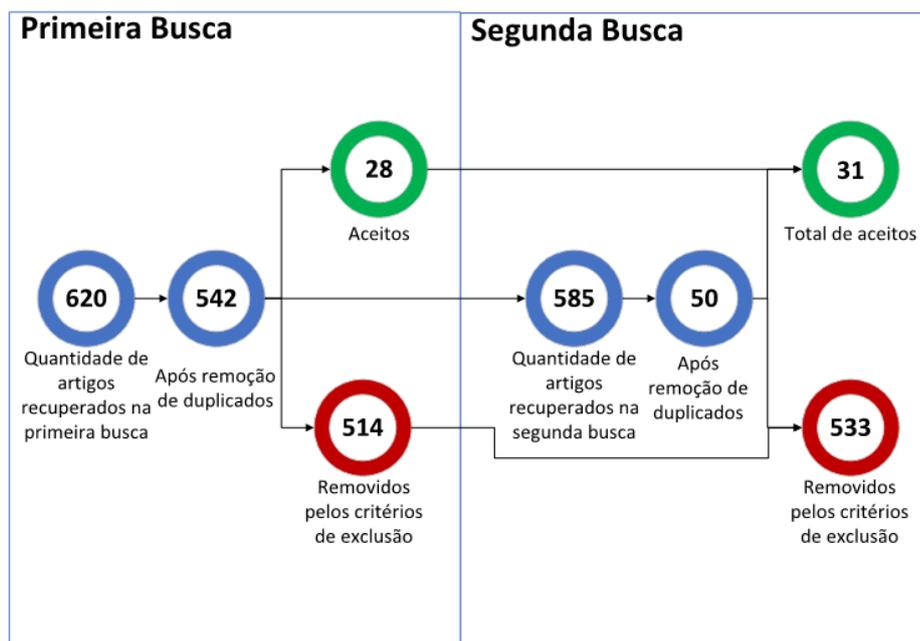
OR cardiac OR heart OR “left ventricle”) AND (characteristic OR feature OR shape) AND (extraction OR descriptor) nos títulos, resumos e palavras-chave dos artigos; enquanto a segunda utilizou a *string* de busca (***MRI OR cine-mri OR “magnetic resonance”) AND (cardiology OR cardiac OR heart OR “left ventricle”) AND (characteristic OR feature OR shape OR index OR indices OR biomarker) AND (extraction OR descriptor)***).

A segunda busca se fez necessária porque foi percebido que muitos artigos utilizavam os termos “*index*”, “*indices*” e “*biomarker*” para referenciar as características intrínsecas das imagens cardíacas, os quais não estavam contemplados na primeira *string* de busca construída.

A figura 8 ilustra o processo e o fluxo das operações realizadas nessa etapa da revisão sistemática. Na primeira busca, 620 artigos foram recuperados inicialmente e, após

remoção de estudos duplicados, restaram 542. Após a aplicação dos critérios de inclusão e exclusão, 28 (5%) artigos foram incluídos. Após a segunda busca, 50 novos artigos foram recuperados e após aplicação dos critérios de inclusão e exclusão, outros três artigos foram incluídos, totalizando 31 (5%) artigos aceitos nessa revisão sistemática.

Figura 8 – Evolução da quantidade de artigos recuperados, aceitos e rejeitados após cada passo.



Fonte – Pedro Henrique Morais Delmondes, 2022

Os artigos aceitos foram analisados e um formulário de extração de dados foi preenchido com as seguintes informações: “Nome do descritor”, “Característica extraída pelo método”, “Ciclo cardíaco analisado”, “Categoria da característica extraída”, “Categoria da técnica utilizada”, “Objetivo técnico”, “Objetivo clínico”, “Métricas de avaliação”, “Tipo de base de dados”, “Natureza da base de dados”, “Tamanho da base de dados”, “Vantagens do descritor”, “Desvantagens do descritor” e “Trabalhos futuros”.

3.3 Análise dos resultados

Após a seleção dos artigos relevantes e extração de suas principais informações em um formulário, uma análise quantitativa e qualitativa dos resultados foi realizada. Essa seção detalha os diferentes aspectos analisados nos artigos aceitos.

3.3.1 Análise geral

Os 31 artigos aceitos nessa revisão sistemática e suas principais informações extraídas estão apresentados no quadro 2. As características extraídas pelos artigos foram categorizadas e estão indicadas na coluna “Categoria do descritor”; esses descritores são explorados na subseção 3.3.2. Os algoritmos desenvolvidos ou aplicados pelos artigos também foram categorizados e estão indicados na coluna “Categoria da técnica”, que é discutida na subseção 3.3.3. A coluna “Tipo de base de dados” indica se a base de dados utilizada para avaliar o método proposto pelo artigo está disponível publicamente ou não; as características dessas bases de dados são exploradas detalhadamente na subseção 3.3.4. A coluna “Objetivo Técnico” (OT) descreve o foco tecnológico do artigo e sua contribuição principal. A coluna “Ciclo” indica o ciclo cardíaco analisado ao extrair a característica. A coluna “Objetivo Clínico” (OC) indica a contribuição do artigo na área da medicina. Essas três últimas colunas são discutidas ao longo dos próximos parágrafos.

Ao analisar o quadro 2, pode-se observar que 28 (90%) dos artigos consideram o ciclo cardíaco completo ao extrair características. Esses artigos geralmente analisam os *frames* em um exame *cine*-MRI cardíaco, abordagem útil para gerar gráficos e analisar a variação das características extraídas ao longo do tempo, por exemplo calcular o volume e a fração de ejeção (KHALIFA *et al.*, 2011; DEKHIL *et al.*, 2018; NACHTOMY *et al.*, 1998; LUO *et al.*, 2016; MESSADI *et al.*, 2018). Essa abordagem também é útil para calcular o deslocamento do ventrículo ao longo do ciclo e extrair características de movimento (SARMIENTO; PICO; MARTINEZ, 2018; PARAGES; BRANKOV, 2012; MANTILLA *et al.*, 2019; LU *et al.*, 2009; MORENO; RODRIGUEZ; MARTÍNEZ, 2019; SANZ-ESTÉBANEZ *et al.*, 2018).

Nesse trabalho foram definidas quatro categorias de Objetivo Técnico, de acordo com o foco e contribuição dos trabalhos:

- “Descritor” - trabalhos focados em desenvolver e apresentar novas características extraídas dos exames;
- “Segmentação” - trabalhos que propuseram novas maneiras de realizar a segmentação de imagem e, como parte do processo, extraem características a partir da área segmentada;
- “Aplicação” - trabalhos que aplicaram descritores propostos em outros artigos;

Quadro 2 – Dados gerais dos estudos incluídos na revisão sistemática da literatura (OT = Objetivo Técnico; OC = Objetivo Clínico; PI = Processamento de Imagem).

Índice	Artigo	Categoria do descritor	Categoria da Técnica	Tipo de base de dados	OT	Ciclo	OC
1	Altabella et al. (2017)	Forma; Clínico	PI; Outros	Proprietária	Descritor	Completo	Extração
3	Nageswararao e Srinivasan (2017)	Forma; Textura	IA Clássica	Proprietária	<i>Framework</i>	Completo	Classificação
3	Goyal et al. (2019)	Forma; Clínico	IA Clássica	Não mencionada	<i>Framework</i>	Completo	Extração
4	Khalifa et al. (2011)	Clínico	PI; Modelos Deformáveis	Híbrida	Segmentação	Completo	Extração
5	Dekhil et al. (2018)	Forma; Clínico	IA Clássica; Aprendizado profundo	Proprietária	Segmentação	Completo	Extração
6	Bollache et al. (2010)	Clínico	PI; IA Clássica	Proprietária	Segmentação	Diástole	Classificação
7	Nachtomy et al. (1998)	Forma; Clínico	PI	Proprietária	Segmentação	Completo	Extração
8	Sarmiento, Pico e Martínez (2018)	Movimento	PI; IA Clássica	Pública	Descritor	Completo	Classificação
9	Tan et al. (2016)	Movimento	Outros	Pública	Descritor	Completo	Quantificação
10	Luo et al. (2016)	Forma; Clínico	Aprendizado Profundo; Outros	Pública	Descritor	Completo	Extração
11	Florack, Assen e Suinesiaputra (2007)	Movimento	PI	Não mencionada	Descritor	Sístole	Quantificação
12	Parages e Brankov (2012)	Movimento	IA Clássica; Modelos deformáveis	Proprietária	Descritor	Completo	Classificação
13	Messadi et al. (2018)	Forma; Clínico	PI	Híbrida	Segmentação	Completo	Extração
14	Li et al. (2020)	Clínico	PI; Aprendizado Profundo	Proprietária	Descritor	Completo	Extração
15	Xue et al. (2017)	Forma; Clínico	Aprendizado Profundo	Proprietária	Descritor	Completo	Extração
16	Du et al. (2018)	Forma	Aprendizado Profundo	Proprietária	Descritor	Completo	Extração
17	Mantilla et al. (2019)	Movimento	IA Clássica	Híbrida	Descritor	Completo	Classificação
18	Müller et al. (2004)	Forma; Movimento	Outros	Proprietária	Descritor	Completo	Classificação
19	Mishra, Dutta e Ghosh (2006)	Movimento	PI	Proprietária	Descritor	Completo	Quantificação
20	Elnakib et al. (2015)	Movimento	PI; Modelos Deformáveis	Proprietária	Descritor	Completo	Quantificação
21	Rohé, Sermesant e Pennec (2018)	Movimento	PI; IA Clássica	Proprietária	Descritor	Completo	Quantificação
22	Chenoune et al. (2012)	Clínico	PI; IA Clássica	Proprietária	Descritor	Diástole	Quantificação
23	Kurzendorfer et al. (2018)	Textura	PI; IA Clássica	Proprietária	Descritor	Completo	Quantificação
24	Lu et al. (2009)	Movimento	Outros	Proprietária	Descritor	Completo	Classificação
25	Xing et al. (2017)	Movimento	PI	Pública	Descritor	Completo	Quantificação
26	Wang et al. (2019)	Forma	Aprendizado Profundo	Proprietária	Segmentação	Completo	Extração
27	Neisius et al. (2019)	Textura	PI; IA Clássica	Proprietária	Aplicação	Completo	Classificação
28	Moreno, Rodriguez e Martínez (2019)	Movimento	PI; IA Clássica	Pública	Descritor	Completo	Classificação
29	Xu et al. (2020)	Clínico	Aprendizado Profundo	Proprietária	Segmentação	Completo	Quantificação
30	Eftestøl et al. (2012)	Textura; Clínico	IA Clássica	Proprietária	Aplicação	Completo	Classificação
31	Sanz-Estébanez et al. (2018)	Movimento	PI	Proprietária	Descritor	Completo	Classificação

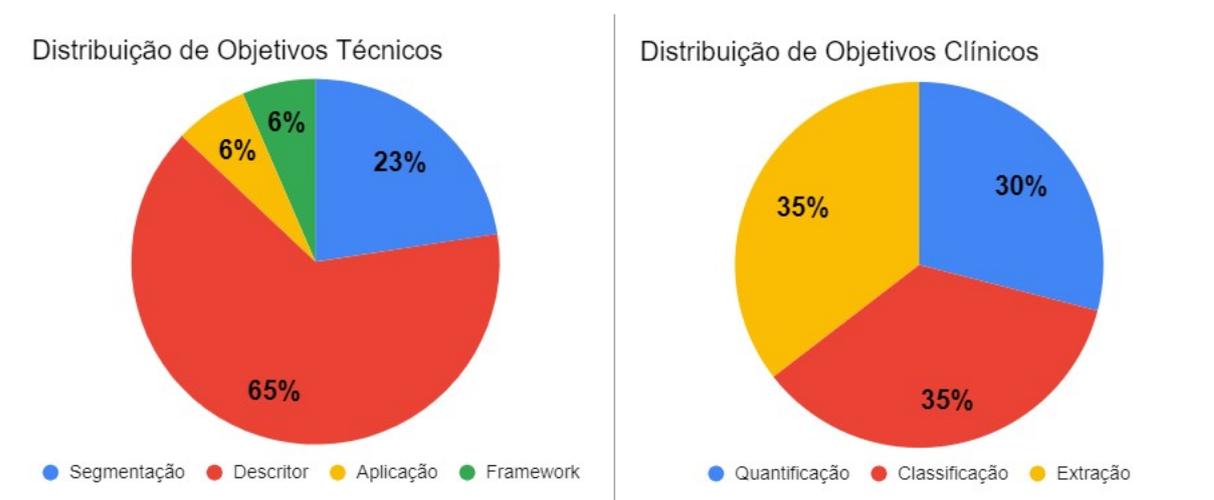
- “*Framework*” - trabalhos que apresentam soluções integradas de segmentação, extração de características, e classificação de imagens.

Também foram definidas três categorias de Objetivo Clínico, de acordo com a contribuição dos trabalhos para a área de saúde: Extração, Classificação e Quantificação. Essas categorias e o critério adotado para a categorização foram assim definidos:

- Extração - trabalhos objetivando prover informação adicional para o profissional de saúde, extraíndo parâmetros e características dos exames;
- Classificação - trabalhos que objetivam auxiliar o diagnóstico classificando se um determinado paciente possui um coração com aspectos considerados normais ou anormais, se o coração possui ou não determinada patologia ou se é recomendado que o paciente utilize um determinado dispositivo cardíaco de acordo com as características extraídas;
- Quantificação - trabalhos que quantificam o movimento do coração durante o ciclo cardíaco ou quantificam condições anormais do tecido cardíaco como tecido cicatrizado ou área infartada, auxiliando o profissional da saúde na análise da condição de um paciente.

Na figura 9 são apresentados dois gráficos que indicam a distribuição das classes e OT e OC na população dos artigos incluídos.

Figura 9 – Frequência de cada Objetivo Clínico e Objetivo Técnico



Fonte – Pedro Henrique Morais Delmondes, 2022

3.3.2 Descritores

O quadro 2 mostra que ainda não existe consenso entre os pesquisadores sobre qual tipo de descritor é o mais adequado para diagnosticar uma determinada doença cardíaca. Nesse sentido, pesquisas que extraem diversos tipos de características têm sido desenvolvidas. Os descritores foram categorizados em quatro tipos, conforme apresentados no quadro 3:

- Forma - descritores dessa categoria descrevem as imagens de um exame morfológica-mente. Esses descritores normalmente processam o conjunto de *pixels* identificados após um processo de segmentação que identifica os contornos da imagem;
- Textura - descritores que extraem padrões visuais de uma imagem como granularidade, direção e repetitividade;
- Movimento - descritores obtidos ao analisar a variação da estrutura cardíaca ao longo do ciclo cardíaco por meio do conjunto de *frames* de um exame. Características de movimento são comumente expressas na forma de histogramas ou em vetores de deslocamento;
- Clínico - descritores calculados a partir do processamento da imagem para mensurar um aspecto fisiológico ou anatômico. Esses parâmetros são bem conhecidos no meio médico e, por isso, podem ser facilmente interpretados para auxiliar a análise da saúde de um paciente.

Na figura 10 é apresentada a frequência dos descritores mais citados nos artigos aceitos. Alguns descritores que são equivalentes, mas que foram citados com nomes diferentes foram combinados e estão representados com um nome único.

Na categoria “Forma” o descritor de volume da cavidade é o mais utilizado entre os artigos aceitos, sendo citado por Goyal *et al.* (2019), Dekhil *et al.* (2018), Nachtomy *et al.* (1998), Luo *et al.* (2016), Messadi *et al.* (2018) e Müller *et al.* (2004). Na categoria “Textura”, os descritores mais populares são o padrão binário, citado por Neisius *et al.* (2019), Kurzendorfer *et al.* (2018); características de Haralick, citado em Nageswararao e Srinivasan (2017) e Eftestøl *et al.* (2012); e os descritores baseados em matriz de co-ocorrência, citados em Neisius *et al.* (2019) e Eftestøl *et al.* (2012). Na categoria “Movimento” os de vetores de deslocamento foram os mais citados (TAN *et al.*, 2016; FLORACK; ASSEN; SUINESIAPUTRA, 2007; PARAGES; BRANKOV, 2012; MISHRA; DUTTA; GHOSH,

Quadro 3 – Descritores Extraídos

Categoria	Descritor	Artigos
Forma	Área da cavidade; Área do miocárdio; Dimensão; Volume da cavidade; Volume do miocárdio; Espessura da parede; Momentos de Hu; Momentos de Flusser	Altabella <i>et al.</i> (2017), Nageswararao e Srinivasan (2017), Goyal <i>et al.</i> (2019), Dekhil <i>et al.</i> (2018), Nachtomy <i>et al.</i> (1998), Luo <i>et al.</i> (2016), Messadi <i>et al.</i> (2018), Xue <i>et al.</i> (2017), Du <i>et al.</i> (2018), Müller <i>et al.</i> (2004), Wang <i>et al.</i> (2019)
Textura	Matriz <i>Run-Length</i> ; Padrão local binário; Histograma de textura; Matriz de co-ocorrência; Valor médio de cinza; Dimensão fractal; Tamanho do objeto binário; Características de Haralick	Nageswararao e Srinivasan (2017), Kurzendorfer <i>et al.</i> (2018), Neisius <i>et al.</i> (2019), Eftestøl <i>et al.</i> (2012)
Movimento	Histograma de movimento; Vetores de deslocamento; Campo de movimento; Perfil espaço-temporal; Velocidade de torção ao longo do tempo; Movimento da parede ao longo do tempo; Campo de fluxo vetorial; Tensão funcional; Orientação de fluxo; Movimento rotacional	Sarmiento, Pico e Martinez (2018), Tan <i>et al.</i> (2016), Florack, Assen e Suinesiaputra (2007), Parages e Brankov (2012), Mantilla <i>et al.</i> (2019), Müller <i>et al.</i> (2004), Mishra, Dutta e Ghosh (2006), Elnakib <i>et al.</i> (2015), Rohé, Sermesant e Pennec (2018), Lu <i>et al.</i> (2009), Xing <i>et al.</i> (2017), Moreno, Rodriguez e Martínez (2019), Sanz-Estébanez <i>et al.</i> (2018)
Clínico	Fração de volume extracelular; Massa do miocárdio; Fração de ejeção; Volume sistólico; Curva de inclinação Sistólica/Diastólica; Velocidade diastólica; Taxa de fluxo diastólico; Amplitude de contração; Extensão de tecido infartado	Altabella <i>et al.</i> (2017), Goyal <i>et al.</i> (2019), Khalifa <i>et al.</i> (2011), Dekhil <i>et al.</i> (2018), Bollache <i>et al.</i> (2010), Nachtomy <i>et al.</i> (1998), Luo <i>et al.</i> (2016), Messadi <i>et al.</i> (2018), Li <i>et al.</i> (2020), Xue <i>et al.</i> (2017), Chenoune <i>et al.</i> (2012), Xu <i>et al.</i> (2020), Eftestøl <i>et al.</i> (2012)

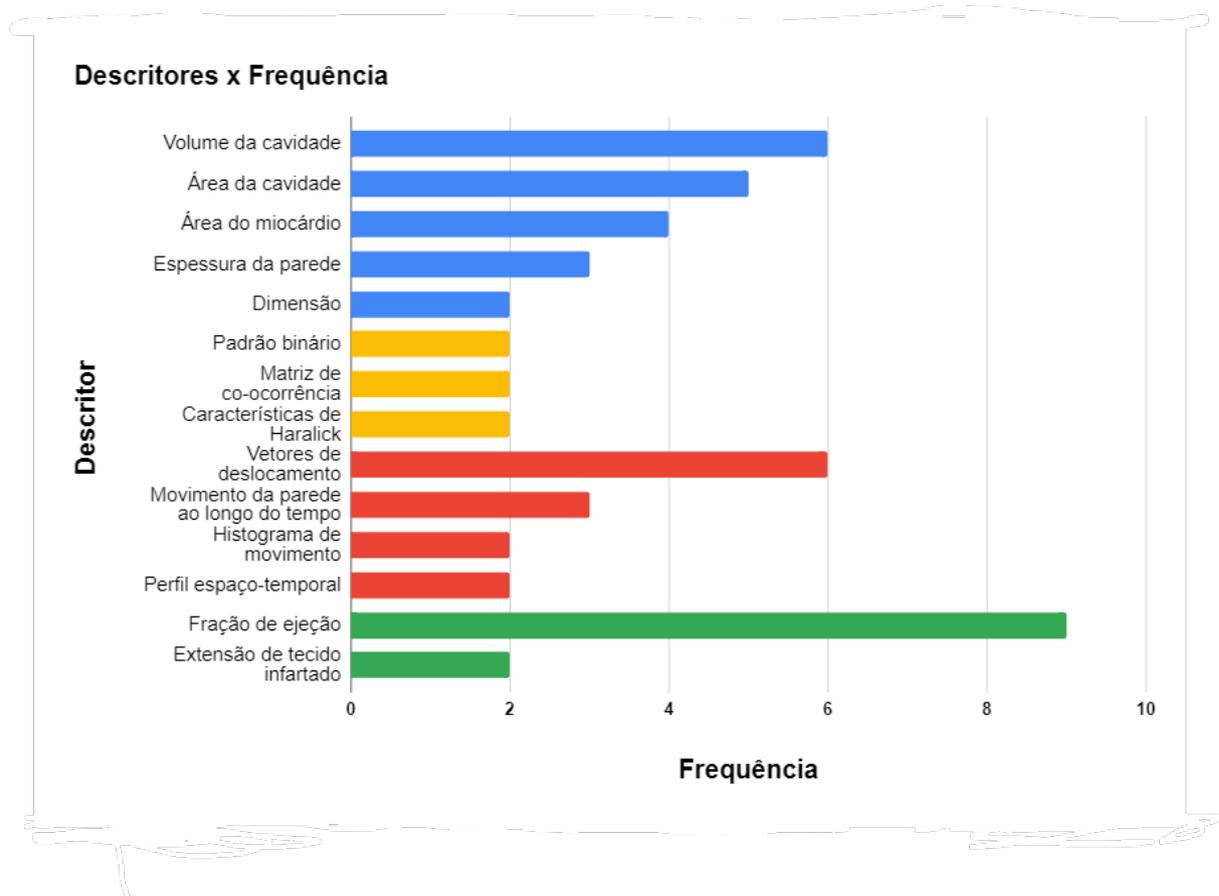
Fonte – Pedro Henrique Morais Delmondes, 2022

2006; MORENO; RODRIGUEZ; MARTÍNEZ, 2019; SANZ-ESTÉBANEZ *et al.*, 2018).

A fração de ejeção é o descritor “Clínico” mais utilizado, sendo citado em Goyal *et al.* (2019), Khalifa *et al.* (2011), Dekhil *et al.* (2018), Nachtomy *et al.* (1998), Luo *et al.* (2016), Messadi *et al.* (2018), Li *et al.* (2020), Xue *et al.* (2017) e Eftestøl *et al.* (2012). A fração de ejeção é normalmente calculada a partir de outros parâmetros, como a área e volume da cavidade, classificados como do tipo “Forma”; essa é uma das razões de existirem vários artigos com ambos extratores do tipo “Forma” e “Clínico” conforme visto no quadro 2.

A figura 11 sumariza a quantidade de artigos que utiliza cada categoria de descritores considerando cada OT e OC. Pode se observar que artigos com OT de “Segmentação” utilizam exclusivamente descritores de “Forma” e “Clínico”, uma vez que essas características são facilmente derivadas a partir de uma imagem segmentada. Adicionalmente, artigos que utilizam esses dois tipos de descritores sempre possuem OC de “Extração”. Todos os artigos que utilizam descritores do tipo “Movimento” possuem OT de “Descritor”, uma vez que todos objetivam apresentar novas maneiras de quantificar o movimento do ventrículo esquerdo. Esse tipo de descritor também está associado aos OC de “Classificação”

Figura 10 – Frequência de cada descritor nos artigos incluídos (Legenda de cores: Azul = Forma; Amarelo = Textura; Vermelho = Movimento; Verde = Clínico)



Fonte – Pedro Henrique Morais Delmondes, 2022

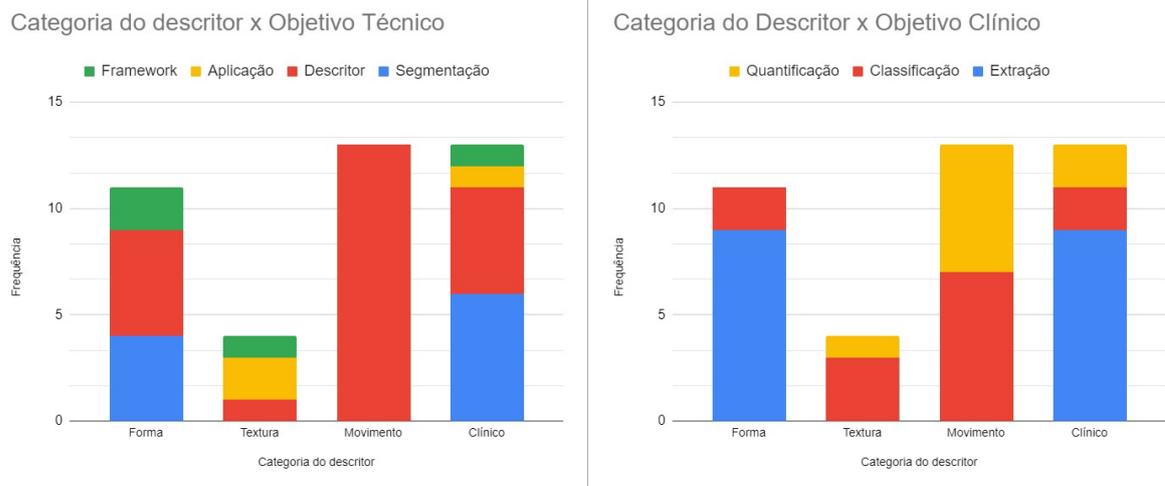
e “Quantificação”, utilizando as características de movimento extraídas para classificar os pacientes quanto à presença de alguma doença cardíaca ou, ainda, para quantificar o movimento do coração ao longo do ciclo por meio da análise dos diferentes *frames*.

3.3.3 Técnicas

As técnicas utilizadas para extrair as características e para realizar tarefas de classificação foram agrupadas em cinco categorias:

- “Processamento de Imagem” - técnica que agrupa algoritmos que detectam padrões de forma, realizam transformações ou compressões geométricas, aplicam filtros de suavização, de detecção ruído ou de frequência;

Figura 11 – Quantidade de artigos aceitos considerando a categoria de descritor e os objetivos técnico e clínico



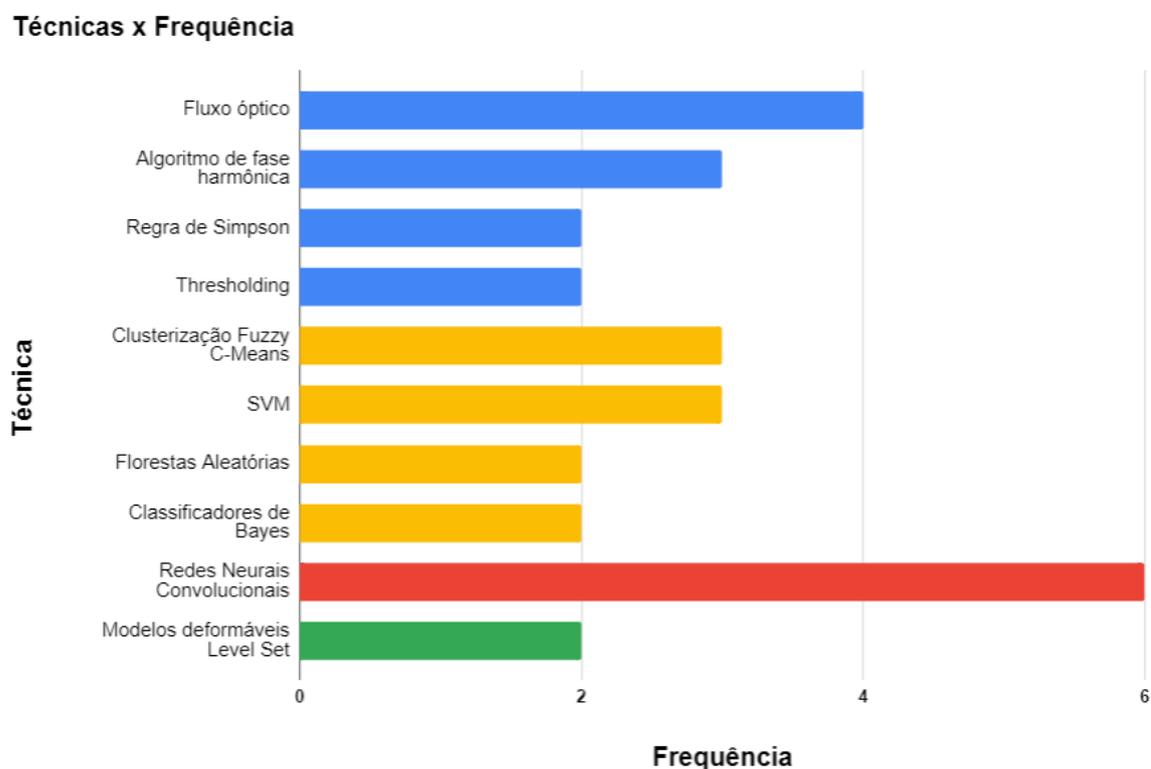
Fonte – Pedro Henrique Morais Delmondes, 2022

- “IA Clássica” - técnicas de inteligência artificial e AM, comumente utilizadas por artigos com OC de “Classificação” por serem úteis para diferenciar se um caso é normal ou anormal com base nas características extraídas;
- “Aprendizado Profundo” - técnicas de IA categorizadas separadamente devido à sua representatividade dentre os artigos recuperados e por utilizarem redes neurais profundas, com muitas camadas, sendo muitas vezes encarados como métodos caixa-preta (KNIGHT, 2017);
- “Modelos Deformáveis” - técnicas que utilizam formas geométricas definidas dentro da imagem que podem se modificar ao longo do tempo sob influência de outras forças externas;
- “Outros” - técnicas que foram utilizadas apenas em um artigo e não se encaixavam nas categorias anteriores.

Na figura 12 são exibidas as técnicas mais citadas nos artigos incluídos. Foi observada uma grande diversidade de técnicas utilizadas, já que 31 técnicas diferentes foram identificadas e apenas dez (32%) delas foram usadas por dois ou mais artigos. A listagem completa de todas as técnicas pode ser conferida no artigo de Delmondes e Nunes (2022).

Dentre as técnicas de “Processamento de Imagem” a mais frequente é o fluxo óptico, sendo utilizado nos trabalhos de Sarmiento, Pico e Martinez (2018), Florack, Assen e Suinesiaputra (2007), Li *et al.* (2020) e Moreno, Rodriguez e Martínez (2019). Na categoria de “IA Clássica”, as técnicas mais utilizadas são o algoritmo de clusterização *fuzzy*, utilizada

Figura 12 – Frequência de cada técnica nos artigos incluídos (Legenda de cores: Azul = Processamento de Imagem; Amarelo = IA Clássica; Vermelho = Aprendizado Profundo; Verde = Modelos Deformáveis).



Fonte – Pedro Henrique Morais Delmondes, 2022

nos artigos de [Nageswararao e Srinivasan \(2017\)](#), [Goyal *et al.* \(2019\)](#) e [Chenoune *et al.* \(2012\)](#) e também o algoritmo de SVM, utilizado para classificar um caso em saudável ou doente como em [Sarmiento, Pico e Martinez \(2018\)](#), [Neisius *et al.* \(2019\)](#) e [Moreno, Rodriguez e Martínez \(2019\)](#). Redes Neurais Convolucionais (CNN - *Convolutional Neural Network*) é o algoritmo de “Aprendizado Profundo” mais comum, utilizado para obter descritores do tipo “Clínico” como a fração de ejeção em [Li *et al.* \(2020\)](#), para executar tarefas de segmentação como em [Dekhil *et al.* \(2018\)](#) e [Wang *et al.* \(2019\)](#) e para obter descritores de “Forma” como o volume do ventrículo esquerdo como visto em [Luo *et al.* \(2016\)](#) e [Du *et al.* \(2018\)](#). No que se refere a “Modelos Deformáveis”, a técnica mais popular é a de *level set*, utilizada para tarefas de “Segmentação” como em [Khalifa *et al.* \(2011\)](#) e [Elnakib *et al.* \(2015\)](#).

3.3.4 Bases de dados públicas

As bases de dados utilizadas pelo artigos incluídos são compostas por conjuntos de imagens de exames de Ressonância Magnética cardíaca. Essas bases de dados foram divididas nas categorias “Proprietária” (quando os dados utilizados para testar os modelos propostos não estão disponíveis publicamente), “Pública” (quando os dados utilizados estão disponíveis publicamente) e “Híbrida” (se os testes foram conduzidos utilizando bases de dados públicas e proprietárias). A categoria “Não mencionado” é utilizada para classificar os artigos em que os autores que não informam que tipo de base de dados foram utilizadas para testar seus modelos.

A maioria dos trabalhos aceitos (21, 68%) utilizam bases de dados proprietárias, enquanto uma menor parte (oito, 26%) avalia sua técnica inteiramente ou parcialmente utilizando uma base de dados disponível publicamente contendo exames obtidos de pacientes reais. Em 72% dos artigos (15 artigos) que citam bases de dados proprietárias, essas apresentam menos de 50 exames. A maior base de dados proprietária possui 232 exames, utilizada em [Neisius *et al.* \(2019\)](#). Para apresentar os detalhes das bases de dados públicas utilizadas nos estudos incluídos, a tabela 1 foi construída.

Na 1, a coluna “Base de dados” indica o nome da base utilizada e também sua referência; a coluna “Usada em” indica trabalhos onde a base em questão foi utilizada; a coluna “Quantidade de casos” contém a quantidade de pacientes em cada base de dados; as colunas “*Slices*” e “*Frames*” indicam a quantidade de *slices* e *frames* em cada um dos casos, respectivamente; e, por último, a coluna “Resolução dos *slices* em *pixels*” indica a resolução de imagem do exame em *pixels*.

Três das bases de dados detalhadas na tabela foram disponibilizadas publicamente como uma das contribuições de artigos que, além disso, apresentavam novos protocolos de aquisição de imagens ou novas técnicas de segmentação ([ANDREOPOULOS; TSOTSOS, 2008](#); [NAJMAN *et al.*, 2007](#); [TOBON-GOMEZ *et al.*, 2013](#)). As outras duas bases de dados detalhadas foram disponibilizadas para fins de competição como campeonatos de segmentação e de estimação de função cardíaca como visto em [Radau *et al.* \(2009\)](#) e [Hamilton \(2014\)](#), respectivamente.

Tabela 1 – Bases de dados públicas usadas pelas abordagens apresentadas nos artigos aceitos e detalhes quantitativos por paciente.

Base de dados	Usada em	Quantidade de casos	<i>Slices</i>	<i>Frames</i>	Resolução dos <i>slices</i> em <i>pixels</i>
<i>Sunnybrook Cardiac Data</i> (RADAU <i>et al.</i> , 2009)	Khalifa <i>et al.</i> (2011), Sarmiento, Pico e Martinez (2018), Moreno, Rodriguez e Martínez (2019)	45	6-12	20	Não informado
Andreopoulos e Tsotsos (2008)	Tan <i>et al.</i> (2016)	33	8-15	20	256 x 256
<i>2015 Data Science Bowl Cardiac Challenge Data</i> (HAMILTON, 2014)	Luo <i>et al.</i> (2016)	1140	11-16	30	Não informado
Najman <i>et al.</i> (2007)	Messadi <i>et al.</i> (2018)	18	9-14	22-37	100 x 100
Tobon-Gomez <i>et al.</i> (2013)	Mantilla <i>et al.</i> (2019), Xing <i>et al.</i> (2017)	15	9-14	13-30	Não informado

Fonte – Pedro Henrique Morais Delmondes, 2022

3.3.5 Avaliação

O uso de métricas de avaliação padronizadas é fundamental para possibilitar a comparação entre resultados obtidos por diferentes estudos. Nessa revisão sistemática observou-se que muitos dos artigos aceitos utilizavam métricas de avaliação comuns entre si. Essas métricas foram categorizadas de acordo com o tipo de análise que os estudos objetivavam executar: segmentação, classificação, descrição e estatística. O quadro 4 apresenta uma visão geral dessas métricas usadas frequentemente pelos trabalhos aceitos.

O coeficiente Dice é a métrica mais utilizada para avaliar tarefas de “Segmentação”, sendo usada em oito (26%) estudos. Essa métrica é obtida ao dividir a intersecção da área da imagem considerada *ground truth* que, em geral, é segmentada manualmente e área segmentada estimada (abordagem proposta) pela área total das duas imagens.

Para avaliar trabalhos com contextos de “Segmentação” e “Classificação”, outras métricas populares foram utilizadas como a Acurácia, Sensibilidade (Revocação) e Especificidade. Em contextos de “Segmentação” essas métricas são usadas para avaliar a segmentação dos *pixels*, classificando-os em Verdadeiro Positivo (VP), Falso Positivo (FP), Verdadeiro Negativo (VN) ou Falso Negativo (FN). Quando usadas em contextos de

Quadro 4 – Métricas de avaliação usadas nas abordagens apresentadas nos artigos aceitos. Legenda: X = Parâmetros Estimados; Y = Parâmetros extraídos manualmente; VP = Verdadeiro Positivo, FP = Falso Positivo, VN = Verdadeiro Negativo, FN = Falso Negativo; R = Soma dos postos; n: Tamanho da amostra; cov = Covariância; σ = Desvio padrão; μ = Média

Categoria	Métrica	Fórmula
Segmentação	Coefficiente Dice	$\frac{2 X \cap Y }{ X + Y }$
Segmentação; Classificação	Acurácia	$\frac{VP + VN}{VP + FP + VN + FN}$
Segmentação; Classificação	Sensibilidade (Revocação)	$\frac{VP}{VP + FN}$
Segmentação; Classificação	Especificidade	$\frac{VN}{FP + VN}$
Classificação	AUC da curva ROC	N/A
Descrição	Erro Médio Absoluto	$\frac{Y - X}{n}$
Descrição; Estatística	Coefficiente de Correlação Linear ρ (Pearson)	$\frac{cov(X, Y)}{\sigma_x \sigma_y}$
Descrição; Estatística	Teste-U de Mann-Whitney	$R_i - \frac{n_i(n_i+1)}{2}$
Estatística	Desvio Padrão	$\sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n}}$

Fonte – Pedro Henrique Morais Delmondes, 2022

“Classificação”, o resultado geral de uma técnica ou modelo de IA é avaliado de acordo com a classe estimada para os exames (normal e com patologia, por exemplo). Nos trabalhos de [Khalifa et al. \(2011\)](#) e [Xu et al. \(2020\)](#) são encontrados exemplos de uso dessas métricas para construir gráficos de Precisão *versus* Revocação e de Característica de Operação do Receptor (Curva ROC - *Receiver Operator Characteristic*). Ao calcular a área sob a curva (AUC - *Area Under the Curve*) é possível comparar o desempenho obtido por duas abordagens diferentes.

O uso da métrica de Erro Médio Absoluto é comum em contextos de “Descrição”. Essa métrica calcula a média das diferenças encontradas entre o parâmetro real e o obtido para cada elemento da população (fração de ejeção estimada pela abordagem e calculada

por especialistas, por exemplo). Métricas estatísticas como o Coeficiente de Correção Linear, citado em sete (23%) artigos, também tem sido empregadas para avaliar os resultados em contextos de “Descrição” por serem úteis para analisar o relacionamento entre duas variáveis aleatórias (volume do ventrículo esquerdo estimado pela abordagem e calculado por especialistas, por exemplo).

3.4 Discussão e oportunidades

Após a análise detalhada dos 31 artigos aceitos, pode-se discutir e inferir respostas às perguntas de pesquisa definidas na seção 3.1 e identificar tendências nessa área de pesquisa:

- Q1: *Quais descritores consideram o conjunto de slices e frames de um exame de Ressonância Magnética?* - Como visto na seção 3.3.2, descritores de diferentes categorias consideram o conjunto de *slices* e *frames* para descrever um exame de Ressonância Magnética do ventrículo esquerdo. A maioria deles procura extrair movimento e estimar a fração de ejeção do coração. Essa descoberta pode ser relacionada ao fato desse tipo de descritores, quando comparados a outros tipos, serem mais informativos quanto à presença ou ausência de uma patologia. Isso permite que médicos tomem melhores decisões ao observar esses parâmetros, sem necessidade de processamento adicional da informação conforme visto na subseção 3.3.1.
- Q2: *Esses descritores foram aplicados na identificação de cardiomiopatias?* - Parcialmente, por volta de 35% dos artigos objetivou identificar se o paciente possui ou não uma doença cardíaca em particular, incluindo cardiomiopatias conforme visto em Müller *et al.* (2004) e Neisius *et al.* (2019). Apesar dos outros artigos não serem focados na identificação de doenças cardíacas, a maioria deles ainda extrai características do ventrículo esquerdo cardíaco e os autores afirmam que os descritores podem ser usados em um sistema CAD completo, no futuro. Isso indica que a construção de sistemas CAD para doenças cardíacas ainda é uma tendência entre os pesquisadores.
- Q3: *Quais conjuntos de dados foram utilizados para avaliar os descritores?* - Na seção 3.3.4 foi identificado que apenas cinco bases de dados públicas foram utilizadas pelos

autores dos artigos aceitos para avaliar seus trabalhos. Três desses foram publicados como uma das contribuições principais de seus artigos, evidenciando o quão difícil e valorizada é a tarefa de coletar dados médicos públicos. Duas dessas bases foram disponibilizadas para fins de competição, sendo a *Sunnybrook Cardiac Data* a mais popular entre elas (RADAU *et al.*, 2009). Essas competições, apesar de terem sido realizadas há alguns anos, continuam sendo uma fonte valiosa de dados, servindo como *benchmark* para trabalhos desenvolvidos recentemente (SARMIENTO; PICO; MARTINEZ, 2018; MORENO; RODRIGUEZ; MARTÍNEZ, 2019), (RIBEIRO, 2021).

- Q4: *Quais métricas foram utilizadas para medir o desempenho dos descritores?* - Conforme visto na seção 4.4, cada objetivo clínico (“Segmentação” / “Classificação” / “Extração”) possui seu próprio conjunto de métricas de avaliação que são bem estabelecidas e consideradas padrão naquela área, atingindo uma quantidade grande de citações entre os artigos aceitos. O coeficiente Dice é a métrica mais utilizada para avaliar “Segmentação”, acurácia para “Classificação” e Erro Médio Absoluto para “Extração”. Todas as métricas são consideradas clássicas em seus domínios de conhecimento e o desenvolvimento de novas métricas não foi considerado pelos autores. Autores mencionam que o gargalo para a comparação de diferentes métodos está na falta de bases de dados públicas disponíveis, ao invés de estar na padronização de métricas.

Analisando os resultados obtidos nessa revisão sistemática, é evidente que trabalhos recentes se concentram em construir três tipos de descritores: volume da cavidade do ventrículo esquerdo, fração de ejeção e vetores de deslocamento estimados. E para estimar essas características, autores têm utilizado técnicas de “Processamento de Imagem” como fluxo óptico para estimar movimento e técnicas como a regra de Simpson para estimar o volume da cavidade.

Definir um único descritor como o mais promissor é tarefa quase impossível, uma vez que cada descritor utiliza técnicas diferentes para atingir seus objetivos técnicos e clínicos. Bem como os próprios autores também utilizam diferentes métricas em artigos com diferentes objetivos, mesmo quando os descritores são os mesmos. Por exemplo, os estudos de Messadi *et al.* (2018) e Xu *et al.* (2020), obtiveram os resultados semelhantes ao utilizar o coeficiente de Dice como métrica. Porém, em Messadi *et al.* (2018) foram

utilizadas técnicas de *thresholding* e contorno ativo para segmentar o endocárdio, enquanto em [Xu et al. \(2020\)](#) foi utilizado uma Rede Neural Convolutiva.

Segundo [Bernard et al. \(2018\)](#) o processo de segmentação de imagens ainda é um desafio em aberto na literatura e, por isso, autores têm explorado o uso de CNNs para estimar parâmetros cardíacos (área, espessura da parede cardíaca, por exemplo) diretamente, sem a necessidade da segmentação prévia da imagem, a partir dos *slices* mediais de um exame ([LI et al., 2020](#); [XUE et al., 2017](#); [DU et al., 2018](#)). Uma oportunidade de melhoria evidente nesse tipo de trabalho seria a utilização de todos os *slices* do exame na estimação de tais parâmetros, possibilitando a extração direta de parâmetros clínicos como a fração de ejeção, como mencionado nos trabalhos [Li et al. \(2020\)](#), [Xue et al. \(2017\)](#) e [Wang et al. \(2019\)](#). Outra tendência observada neste trabalho é o uso de classificadores para detectar anomalias no funcionamento cardíaco baseados em descritores do tipo “Movimento” extraídos, como visto em [Sarmiento, Pico e Martinez \(2018\)](#) e [Parages e Brankov \(2012\)](#).

Observou-se que na maioria dos trabalhos a avaliação é realizada utilizando bases de dados que não estão disponíveis publicamente e que os bancos de dados públicos disponíveis possuem um número de exames menor do que os proprietários (exceto em [Hamilton \(2014\)](#)), fato apontado como fator limitante por alguns autores ([SARMIENTO; PICO; MARTINEZ, 2018](#); [MORENO; RODRIGUEZ; MARTÍNEZ, 2019](#)). A pouca disponibilidade de bases de dados públicas limita a possibilidade de avaliar abordagens diferentes entre si e a reprodutibilidade dos trabalhos. Nesse sentido, a disponibilização de novas bases de dados públicas é fundamental. Nota-se que trabalhos que utilizam bases de dados proprietárias, as viabilizam por meio de parcerias entre os autores e instituições de saúde. Tais entidades poderiam ser incentivadas a realizar um trabalho adicional para disponibilizar essas bases de dados publicamente.

Autores têm utilizado métricas consideradas clássicas para medir a efetividade de suas abordagens. Isso é uma boa prática que deve ser mantida em novos estudos da área, possibilitando a comparação destes com os considerado estado-da-arte. Uma possível melhoria na avaliação dos trabalhos seria conduzir avaliações subjetivas e objetivas com profissionais da saúde, buscando avaliar a efetividade percebida do uso das técnicas e sistemas computacionais propostos em suas rotinas.

3.5 Considerações finais do capítulo

Neste capítulo foram apresentados os resultados obtidos em uma revisão sistemática sobre trabalhos que apresentam descritores que consideram o conjunto de *slices* e *frames* de um exame de Ressonância Magnética cardíaca. Apesar de uma pesquisa extensiva nas principais bases de dados científicas nas áreas da medicina e da computação, foi observado que o número de trabalhos desse tipo ainda é escasso quando comparados com o volume de trabalhos que consideram os *slices* individualmente ou com superfícies 3D reconstruídas. Dessa forma, ainda existe espaço na literatura para contribuições relevantes nessa área.

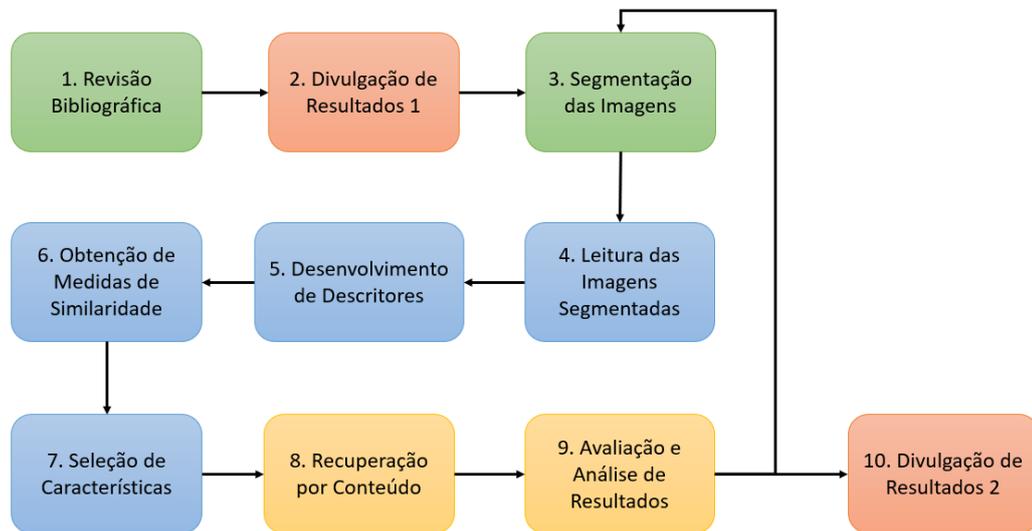
Além disso, mesmo nos descritores que consideram todos os *slices* e *frames*, há espaço para novos estudos: abordagens de “Aprendizado Profundo” podem ser melhoradas para considerar múltiplos *slices* de exames de Ressonância Magnética; descritores como volume da cavidade, volume do miocárdio, vetores de deslocamento e fração de ejeção podem ser utilizados em conjunto com classificadores para avaliar seu desempenho na tarefa de detectar cardiomiopatias. Também foi observado que estudos que comparam implementações diferentes do mesmo descritor e que disponibilizam bases de dados públicas são escassos. Esforços adicionais para disponibilizar bases de dados públicas poderiam viabilizar o desenvolvimento desses estudos comparativos.

No próximo capítulo são apresentados os métodos desenvolvidos durante este projeto de pesquisa, baseando-se em lacunas e oportunidades identificadas na revisão sistemática. Destaca-se a implementação de 18 diferentes descritores que abordam o conjunto total de imagens (*slices* e *frames*) de um exame de Ressonância Magnética.

4 Materiais e Métodos

Conforme exposto na seção 1.2, o objetivo deste trabalho de pesquisa é implementar descritores de exames de Ressonância Magnética cardíaca que utilizem todos os *slices* em todos os *frames* do ciclo cardíaco e empregar as características extraídas para comparar diferentes exames por meio de medidas de similaridade, de modo a auxiliar profissionais da saúde no diagnóstico de cardiomiopatias. Para atingir esse objetivo, o projeto de pesquisa foi dividido em dez etapas, ilustradas na figura 13, que fornece uma visão geral das atividades executadas neste projeto de pesquisa e seus relacionamentos.

Figura 13 – Fluxo geral do processo executado no presente projeto de pesquisa.



Fonte – Pedro Henrique Morais Delmondes, 2022

- 1. Revisão bibliográfica:** uma revisão bibliográfica sistemática da literatura foi desenvolvida como primeira etapa deste projeto de pesquisa, com o objetivo de identificar se descritores do tipo *multi-slice* e *multi-frame* já haviam sido desenvolvidos e aplicados no mesmo contexto deste projeto. Adicionalmente, também foram analisadas as principais técnicas de IA utilizadas na classificação de pacientes em saudáveis e doentes, além de bases de dados provenientes de bases de dados públicas e métricas de avaliação utilizadas. Os detalhes dessa revisão foram apresentados no capítulo 3 e publicados em [Delmondes e Nunes \(2022\)](#).
- 2. Divulgação de resultados 1:** após a conclusão da etapa de revisão bibliográfica, um artigo foi elaborado e publicado no periódico *Computer Methods and Programs in Biomedicine* ([DELMONDES; NUNES, 2022](#)).

3. **Segmentação das imagens:** nessa etapa as imagens de pacientes com cardiomiopatias fornecidas pelo InCor foram obtidas e extraiu-se manualmente as segmentações do endocárdio e epicárdio do ventrículo esquerdo. Essas segmentações foram geradas de maneira semi-automática pelo sistema *Segment* que utiliza o algoritmo descrito em (TUFVESSON *et al.*, 2015).
4. **Leitura das imagens segmentadas:** um módulo foi desenvolvido especificamente para a leitura das imagens cardíacas segmentadas na etapa anterior. Esse módulo tem a função de processar informações do epicárdio e endocárdio das imagens fornecidas e construir estruturas de dados que sejam capazes de armazenar os dados de todas as imagens do exame de forma eficiente.
5. **Desenvolvimento de descritores:** os descritores são construídos de modo que sejam capazes de processar os dados armazenados nas estruturas de dados definidas na etapa anterior, quantificando características intrínsecas das imagens segmentadas e formando um vetor de características. Em um primeiro momento, foram implementados 15 descritores que buscam quantificar o movimento do ventrículo esquerdo ao longo do ciclo cardíaco e, em segundo momento, três descritores adicionais que quantificam o volume do miocárdio em diferentes fases do ciclo cardíaco. Esses descritores serão detalhados na seção 4.2 e foram inspirados por trabalhos anteriores estudados na revisão sistemática (capítulo 3) como em Dekhil *et al.* (2018), Khalifa *et al.* (2011), Li *et al.* (2020), Moreno, Rodriguez e Martínez (2019) e Sarmiento, Pico e Martinez (2018).
6. **Seleção de características:** após a construção do vetor de características com 18 descritores para cada um dos exames, foi executado o algoritmo *Relief* para detecção do subconjunto de descritores mais relevantes para a recuperação das diferentes classes de exame. Os detalhes dessa etapa estão descritos na seção 4.3.
7. **Obtenção de medidas de similaridade:** os vetores de características de cada exame, construídos durante a etapa de desenvolvimento de descritores e seleção de características, são comparados entre si por meio de medidas de similaridade com o objetivo de medir a distância entre os diferentes exames. A Distância Euclidiana, medida clássica de similaridade em contextos de recuperação de informação foi implementada.
8. **Recuperação por conteúdo:** nesse módulo os resultados obtidos ao comparar os diferentes vetores de características são processados de modo a obter métricas de

avaliação que possibilitam a comparação do modelo desenvolvido neste projeto de pesquisa com outros. Detalhes das métricas utilizadas são descritos na seção 4.4.

9. **Avaliação e análise de resultados:** nessa etapa foi realizada a avaliação e a discussão do desempenho do modelo desenvolvido neste projeto de pesquisa, com base nos resultados obtidos. Após a análise dos resultados preliminares, foi possível revisitar as etapas anteriores para aprimoramentos, especialmente as etapas 3 e 5. Os resultados obtidos por este modelo são apresentados e discutidos no capítulo 5.
10. **Divulgação de resultados 2:** nessa etapa final, artigos apresentando e discutindo os resultados obtidos com este modelo serão elaborados e submetidos a periódicos e conferências.

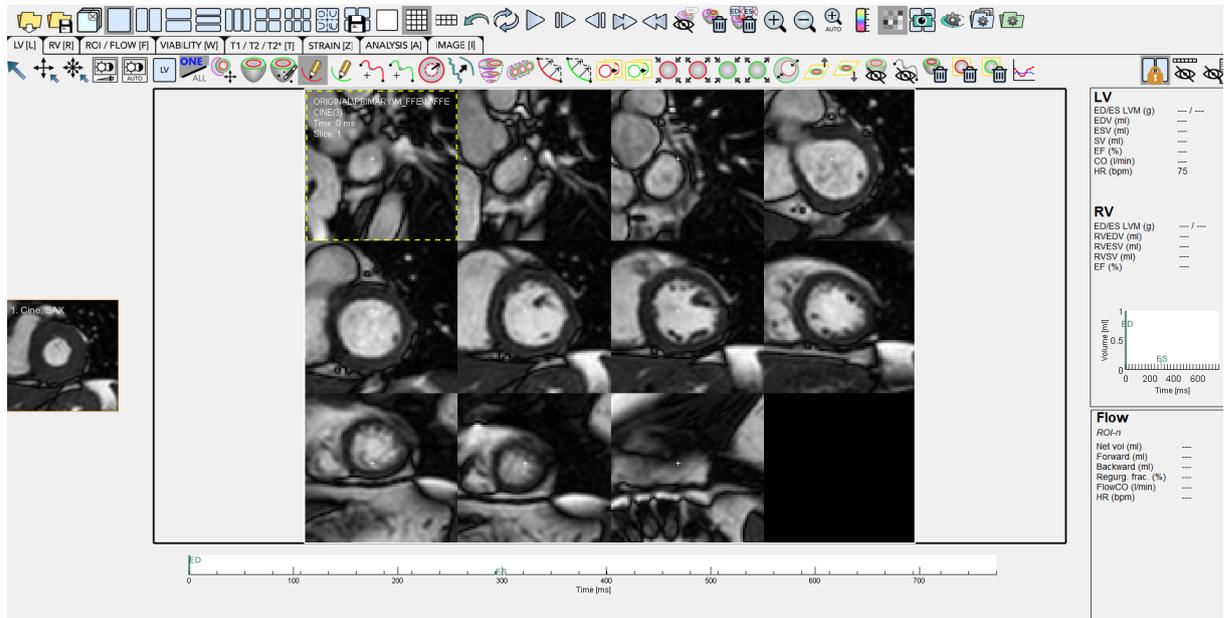
4.1 Conjunto de dados e segmentação

Esta pesquisa foi desenvolvida no Laboratório de Aplicações de Informática em Saúde (LApIS) da Escola de Artes, Ciências e Humanidades (EACH) da Universidade de São Paulo (USP). O referido laboratório possui colaboração com o Instituto do Coração (InCor), o que possibilitou a disponibilização de uma base de imagens de Ressonância Magnética para validação das técnicas desenvolvidas.

Os métodos produzidos neste trabalho foram testados com um conjunto de 384 exames de Ressonância Magnética, de mesma resolução (256 por 256 *pixels*), classificados previamente por especialistas do InCor como normais, portadores de cardiomiopatia dilatada ou portadores de cardiomiopatia hipertrófica. As classes possuem, respectivamente, 101, 170 e 113 casos.

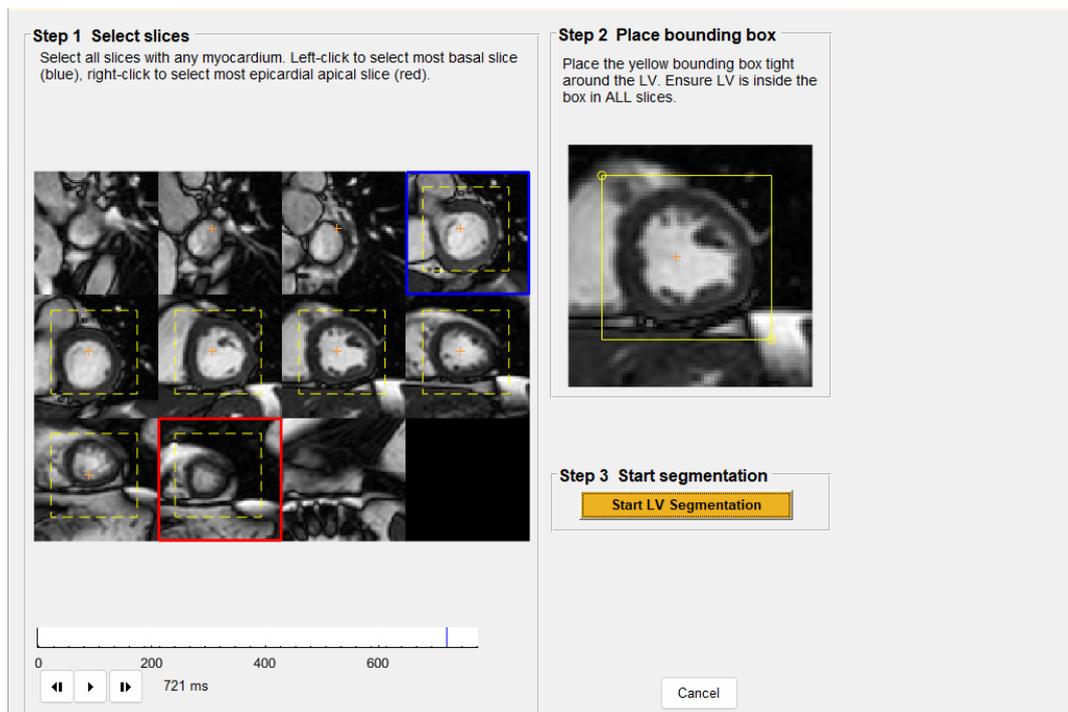
O processo para segmentação e extração dos contornos do endocárdio e epicárdio do ventrículo esquerdo cardíaco foi realizado utilizando o algoritmo de segmentação semi-automática do *software Segment* (TUFVESSON *et al.*, 2015). Para realizar a operação de segmentação semi-automática utilizando esse *software*, primeiro é necessário abrir o arquivo contendo as imagens do exame (figura 14); em seguida seleciona-se os *slices* inicial e final a serem segmentados, ajusta-se a caixa que limita o ventrículo esquerdo na imagem e inicia-se a segmentação (15). O resultado desta operação pode ser visto na figura 16, onde o endocárdio e epicárdio segmentados são exibidos em vermelho e verde, respectivamente.

Figura 14 – Interface do sistema *Segment* com um exame de Ressonância Magnética aberto.



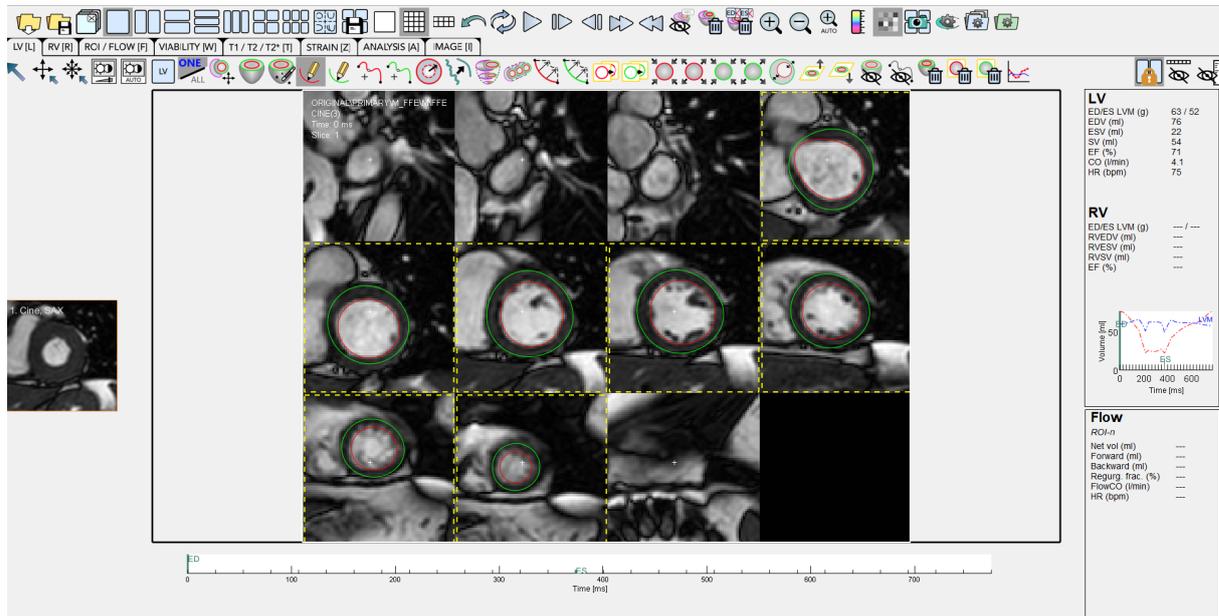
Fonte – Pedro Henrique Morais Delmondes, 2022

Figura 15 – Ferramenta de segmentação semi-automática do ventrículo esquerdo.



Fonte – Pedro Henrique Morais Delmondes, 2022

Figura 16 – Exame com epicárdio (em verde) e endocárdio (em vermelho) segmentados em sete slices do exame.



Fonte – Pedro Henrique Morais Delmondes, 2022

4.2 Descritores

Uma vez que a estrutura contendo os dados de um exame está construída, é possível processar seus dados visando a definir e implementar descritores. Neste trabalho um vetor de características com 18 descritores para cada exame foi construído, conforme descrito a seguir.

Para cada exame analisado, um algoritmo que calcula a distância entre os pontos de cada contorno segmentado é executado objetivando obter o perímetro do endocárdio segmentado em cada um dos *slices* e *frames* do ciclo cardíaco. A partir do perímetro obtido, o raio de cada imagem pode ser calculado para, por fim, obter-se a área segmentada do endocárdio e do epicárdio. Por fim, ao calcular-se a diferença entre a área de um determinado *slice* em um *frame* com a área desse mesmo *slice* no próximo *frame*, é possível obter um valor que indica o quanto a parede cardíaca se deslocou durante este período. Ao repetir essa operação, somando as diferenças obtidas por todos os *frames*, é possível obter o deslocamento total de um *slice* através do ciclo cardíaco. Dos 18 descritores extraídos, 15 são desenvolvidos com base nesse algoritmo.

Para se obter os últimos três descritores: C16, C17 e C18 é necessário considerar também o contorno do epicárdio. Esses três descritores são obtidos ao se calcular a média

das diferenças entre a área segmentada pelo contorno do epicárdio e a área segmentada pelo contorno do endocárdio em todos os *slices* em uma determinada etapa do ciclo cardíaco.

O quadro 5 apresenta a descrição completa de cada um dos 18 descritores desenvolvidos:

Os descritores de C1 a C6 totalizam o movimento do endocárdio durante o ciclo cardíaco completo, ou de uma fase específica, separadamente por *slice*. De modo a considerar exames com diferentes quantidades de *slices*, os descritores C1, C3 e C4 calculam a média aritmética entre valores de deslocamento totalizados em cada um dos *slices*. Esses descritores podem ser úteis para identificar pacientes com cardiomiopatias uma vez que as deformações morfológicas podem prejudicar a capacidade do coração se contrair e expandir, limitando o deslocamento ventricular durante o ciclo cardíaco. A figura 17 ilustra o fluxo do cálculo do descritor C3. Os descritores C2, C5 e C6, por sua vez, calculam o desvio padrão entre os valores de deslocamento totalizado em cada um dos *slices*. Esse tipo de descritor pode ser útil para identificar doenças que afetam diferentemente o deslocamento das seções do ventrículo esquerdo.

Os descritores de C7 a C15 totalizam o movimento do endocárdio através do ciclo cardíaco completo, ou de uma fase específica, para um único *slice*: basal, medial ou apical. Esses descritores podem ser úteis para identificar cardiomiopatias que impactam o movimento de uma seção específica da cavidade do ventrículo esquerdo.

Já os descritores de C16 a C18, totalizam a espessura e volume do miocárdio em três diferentes etapas do ciclo cardíaco. Esse tipo de descritor pode ser útil para diferenciar indivíduos das duas classes de cardiomiopatias estudadas (hipertrófica e dilatada) uma vez que as duas doenças podem afetar a capacidade de deslocamento do ventrículo esquerdo, obtendo valores similares nos descritores de C1 a C15. A figura 18 ilustra o fluxo do cálculo do descritor C16.

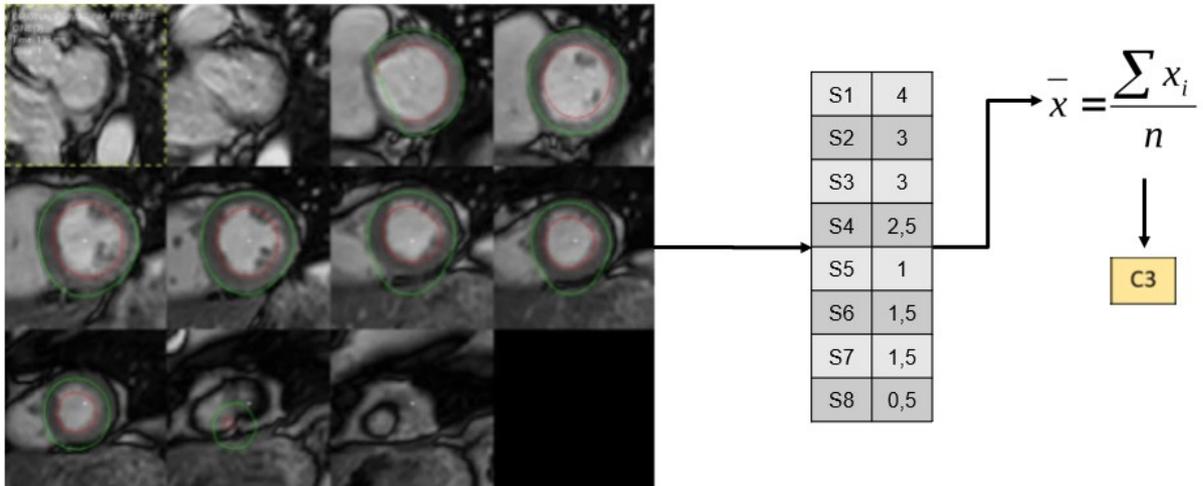
4.3 Algoritmo Relief

Para se otimizar o vetor de características construído pelos descritores apresentados na seção anterior, utilizamos o algoritmo de seleção de características *Relief*, apresentado na seção 2.5. Foram realizadas dez rodadas do algoritmo, cada uma selecionando uma amostra aleatória de 38 elementos do conjunto de dados. O resultado final do algoritmo foi

Quadro 5 – Descritores desenvolvidos que compõem o vetor de características de cada exame.

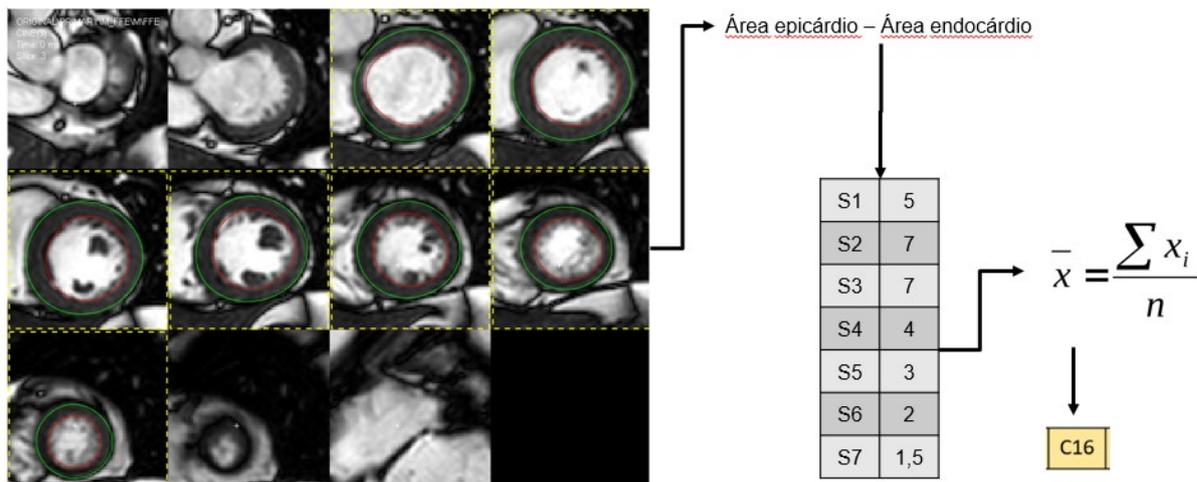
Descritor	Descrição
C1	média do deslocamento total por <i>slice</i> no ciclo cardíaco completo: um vetor no qual cada posição totaliza o deslocamento total de cada <i>slice</i> é construído e, em seguida, a média entre os valores armazenados é extraída
C2	desvio padrão do deslocamento total de cada <i>slice</i> no ciclo cardíaco completo: um vetor no qual cada posição totaliza o deslocamento total de cada <i>slice</i> é construído e, em seguida, o desvio padrão entre os valores armazenados é extraído
C3	média do deslocamento total por <i>slice</i> durante a sístole: similar ao descritor C1, porém o deslocamento é computado somente a partir do <i>frame</i> de fim da diástole até o <i>frame</i> de fim da sístole
C4	desvio padrão do deslocamento total por <i>slice</i> durante a sístole: similar ao descritor C2, porém o deslocamento é computado somente a partir do <i>frame</i> de fim da diástole até o <i>frame</i> de fim da sístole
C5	média do deslocamento total por <i>slice</i> durante a diástole: similar ao descritor C1, porém o deslocamento é computado somente a partir do <i>frame</i> de fim da sístole até o <i>frame</i> de fim da diástole
C6	desvio padrão do deslocamento total por <i>slice</i> durante a diástole: similar ao descritor C2, porém o deslocamento é computado somente a partir do <i>frame</i> de fim da sístole até o <i>frame</i> de fim da diástole
C7	deslocamento total do <i>slice</i> basal no ciclo cardíaco completo
C8	deslocamento total do <i>slice</i> medial no ciclo cardíaco completo
C9	deslocamento total do <i>slice</i> apical no ciclo cardíaco completo
C10	deslocamento total do <i>slice</i> basal durante a sístole
C11	deslocamento total do <i>slice</i> medial durante a sístole
C12	deslocamento total do <i>slice</i> apical durante a sístole
C13	deslocamento total do <i>slice</i> basal durante a diástole
C14	deslocamento total do <i>slice</i> medial durante a diástole
C15	deslocamento total do <i>slice</i> apical durante a diástole
C16	média entre todos os <i>slices</i> do volume do miocárdio no fim da diástole
C17	média entre todos os <i>slices</i> do volume do miocárdio no meio da sístole
C18	média entre todos os <i>slices</i> do volume do miocárdio no fim da sístole

Figura 17 – Fluxo de cálculo do descritor C3, no qual a média do deslocamento de cada *slice* é obtida.



Fonte – Pedro Henrique Morais Delmondes, 2022

Figura 18 – Fluxo de cálculo do descritor C16, no qual a média do volume de cada *slice* no fim da diástole é obtida.



Fonte – Pedro Henrique Morais Delmondes, 2022

obtido a partir da média dos resultados obtidos nas dez rodadas e os sete descritores com maior peso médio foram selecionados para compor o vetor de características otimizado.

4.4 Avaliação das técnicas

Após a obtenção dos vetores de características de cada um dos 384 exames, estes foram comparados por meio da Distância Euclidiana, medida de similaridade apresentada na seção 2.4. Calculando-se essa medida para todos os pares de exames, pode-se determinar quais exames são os mais similares à qualquer exame escolhido como parâmetro.

As medidas de distância entre todos os exames obtidas, podem então ser utilizadas para construir o gráfico de Precisão *versus* Revocação e a Matriz de Distâncias, que foram definidos na seção 2.6. Essas duas métricas avaliam o desempenho geral do sistema CBIR desenvolvido neste trabalho em comparação com trabalhos anteriores.

4.5 Considerações finais do capítulo

Neste capítulo foram descritas as etapas e tarefas realizadas neste projeto de pesquisa, com ênfase no método de segmentação utilizado e nos descritores desenvolvidos, que abordam todos os *slices* e *frames* dos exames. No próximo capítulo serão apresentados e discutidos os resultados obtidos ao se utilizar essas técnicas.

5 Resultados e Discussões

Neste capítulo serão apresentados e discutidos os resultados obtidos ao aplicar o método proposto no capítulo 4. Inicialmente, na seção 5.1, são explorados os resultados obtidos pela técnica de segmentação; na seção 5.2 apresentamos as características apontadas como mais relevantes pelo algoritmo *Relief*; nas seções e o desempenho geral do sistema CBIR é apresentado por meio das medidas de avaliação AUC do Gráfico de Precisão *versus* Revocação e Matriz de Distâncias obtidas; adicionalmente, um outro experimento foi realizado após a estratificação do conjunto de dados. As mesmas métricas foram utilizadas para avaliar este experimento e seu desempenho é apresentado na seção 5.5; por fim, as considerações finais do capítulo são apresentadas na seção 5.7

5.1 Segmentação

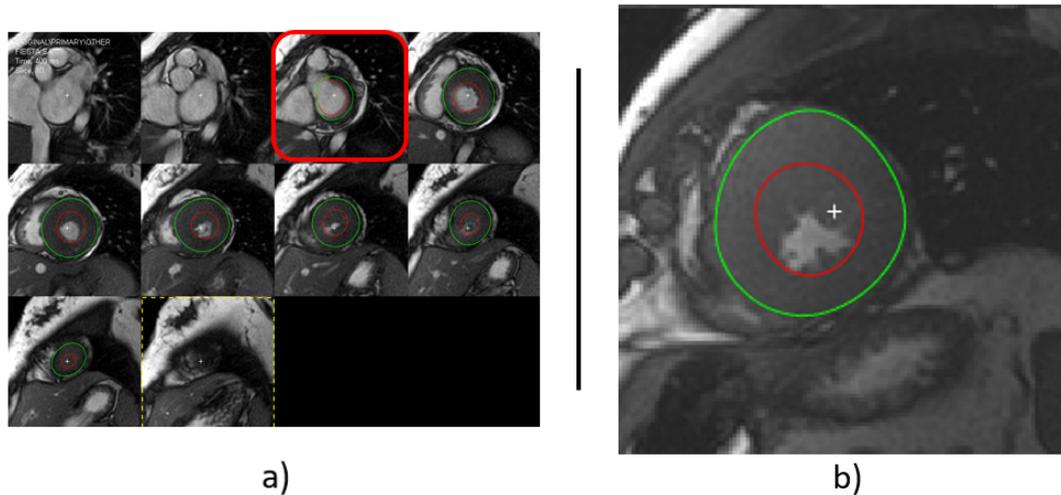
O processo de segmentação semi-automática disponibilizado pelo *software Segment*, apresentado na seção 4.1, foi capaz de gerar segmentações anatomicamente precisas, onde o endocárdio e epicárdio assumem formatos de oval e onde o contorno do epicárdio sempre estava contido no contorno do epicárdio.

Contudo, algumas limitações do algoritmo puderam ser observadas:

- Para se obter as consistências anatômicas algumas vezes foi necessário desprezar *slices* das extremidades basal e apical do ventrículo esquerdo como no exemplo da figura 19a), onde o *slice* basal segmentado apresenta contorno impreciso;
- Nos *frames* de sístole é comum que o contorno do endocárdio se perca e não contraia de forma a acompanhar o movimento do endocárdio e a cavidade do ventrículo esquerdo, como no exemplo da figura 19b).
- Na figura 19b) também é possível observar que os contornos gerados pelo algoritmo, apesar de ovais ou circulares, não são capazes de acompanhar exatamente o epicárdio e endocárdio.

Devido à natureza de quantificar precisamente o deslocamento do endocárdio em 15 dos 18 descritores desenvolvidos, as limitações do método de segmentação descritas acima podem prejudicar o desempenho geral do sistema CBIR, uma vez que o movimento do contorno do endocárdio pode não ser quantificado corretamente.

Figura 19 – Exemplos de limitações apresentadas ao utilizar o método semi-automático de segmentação. (a) *slice* basal apresenta segmentação anatomicamente incorreta; (b) imagem segmentada em um *frame* de sístole onde é possível perceber que o contorno do endocárdio em vermelho não acompanha o movimento do endocárdio.



Fonte – Pedro Henrique Morais Delmondes, 2022

5.2 Seleção de Características

De modo a otimizar os vetores de características construídos para cada paciente após a etapa de extração de características, o algoritmo *Relief* foi utilizado, conforme descrito na seção 4.3. Em um primeiro momento o algoritmo foi executado nos vetores de 15 características (de C1 à C15), e após a implementação das características C16, C17 e C18, o algoritmo foi novamente executado nos vetores de características, agora com 18 posições. A tabela 2 apresenta os vetores de características ordenados pela relevância de cada característica, de acordo com o algoritmo.

Após avaliação do desempenho da abordagem proposta nesse trabalho com diferentes tamanhos de vetores definiu-se o corte ideal para o vetor de 15 posições em 6 características e em 7 características para o vetor de 18 posições.

Nota-se que as características relacionadas ao desvio padrão do deslocamento de cada *slice* durante o ciclo cardíaco (C2, C4 e C6) não foram selecionadas pelo algoritmo, o que pode indicar que as anomalias estudadas por este trabalho não afetam o movimento de segmentos do ventrículo esquerdo separadamente, mas sim de forma uniforme.

O resultado do algoritmo ao ser aplicado no vetor com 18 características demonstra que as três características de volume, implementadas posteriormente, são relevantes para

Tabela 2 – Medidas de AUC obtidas em cada um dos conjuntos de pacientes estratificados.

15 características	18 características
C14	C17
C1	C18
C8	C16
C11	C15
C7	C8
C10	C1
C3	C13
C5	C9
C13	C3
C2	C5
C9	C14
C6	C12
C15	C10
C4	C2
C12	C4
	C11
	C6
	C7

Fonte – Pedro Henrique Morais Delmondes, 2022

o problema apresentado. Isso pode ser explicado devido à natureza das cardiomiopatias estudadas, hipertrófica e dilatada, onde ambas afetam a espessura do miocárdio do ventrículo esquerdo dos pacientes.

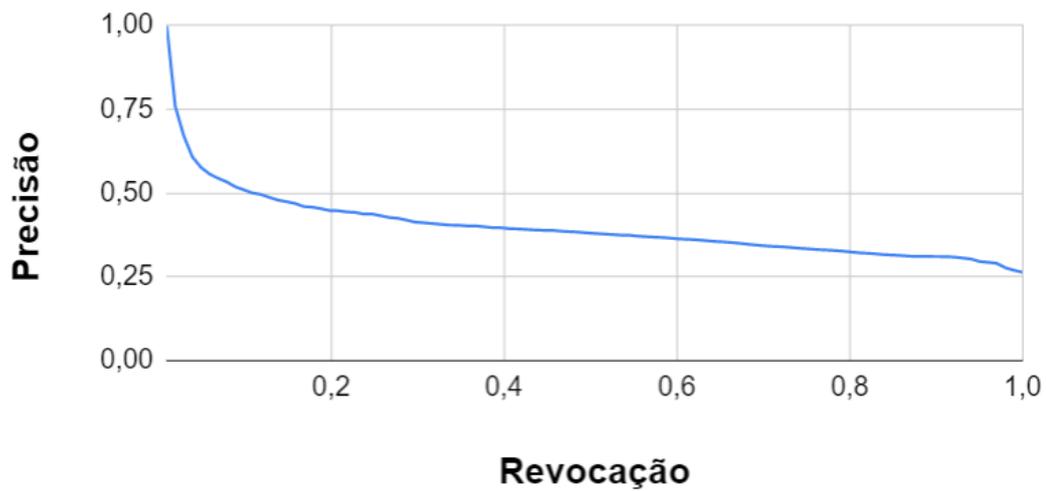
5.3 Recuperação de exames utilizando vetor de 15 características

Na primeira rodada de testes os exames foram comparados utilizando 6 características selecionadas a partir do vetor de características de 15 posições, que consideravam apenas o movimento do endocárdio durante o ciclo cardíaco. As figuras 20, 21 e 22 apresentam as curvas de Precisão *versus* Revocação com seus respectivos valores de AUC, obtidos ao analisar os pacientes com cada um dos três tipos de anomalia.

Ao analisar as curvas dos gráficos de Precisão *versus* Revocação é possível observar que, de forma geral, valores de precisão aquém do esperado foram obtidos, com valores de

Figura 20 – Gráfico da curva de Precisão *versus* Revocação dos pacientes diagnosticados como sem anomalia utilizando um vetor de 15 características. AUC obtida = 0,3981.

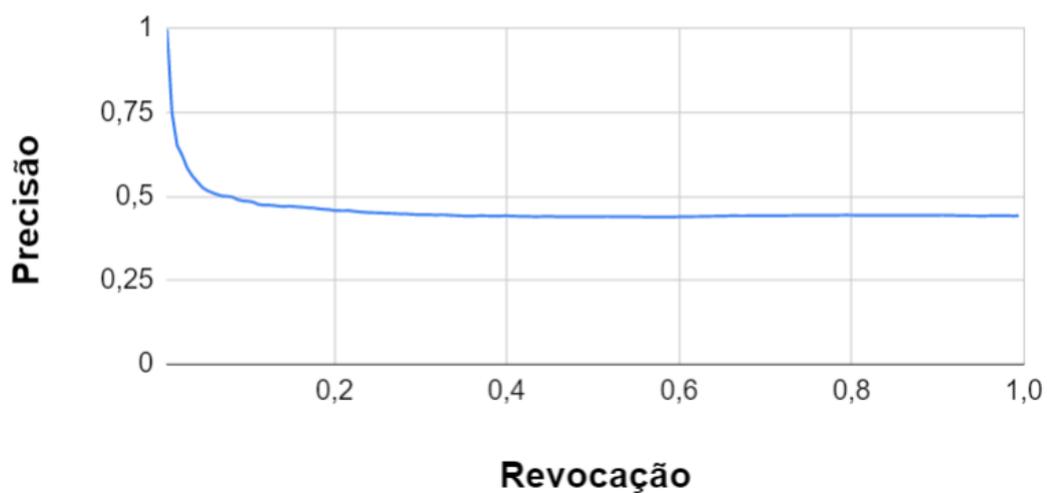
Precisão versus Revocação - Sem anomalia



Fonte – Pedro Henrique Morais Delmondes, 2022

Figura 21 – Gráfico da curva de Precisão *versus* Revocação dos pacientes diagnosticados com cardiomiopatia hipertrófica utilizando um vetor de 15 características. AUC obtida = 0,4584.

Precisão versus Revocação - Hipertróficos



Fonte – Pedro Henrique Morais Delmondes, 2022

Figura 22 – Gráfico da curva de Precisão *versus* Revocação dos pacientes diagnosticados com cardiomiopatia dilatada utilizando um vetor de 15 características. AUC obtida = 0,3083.



Fonte – Pedro Henrique Morais Delmondes, 2022

AUC abaixo de 0,5 e com os valores de precisão diminuindo de forma intensa antes mesmo de 10% dos exames relevantes serem recuperados.

5.4 Recuperação de exames utilizando 18 características

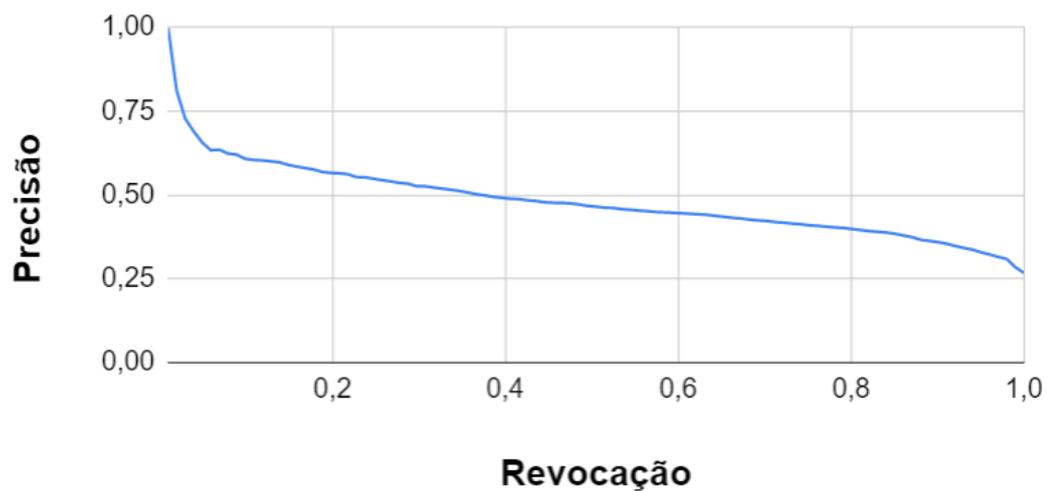
Para a segunda rodada de testes três novos descritores (C16, C17 e C18) foram elaborados e implementados, totalizando 18 características, dentre as quais 7 foram selecionadas pelo algoritmo *Relief* de seleção de características.

Esses três novos descritores levam em consideração o contorno do epicárdio em conjunto com o contorno do endocárdio, possibilitando o cálculo do volume do miocárdio em cada instante do ciclo cardíaco. As figuras 23, 24 e 25 apresentam as curvas de Precisão *versus* Revocação com seus respectivos valores de AUC, obtidos ao analisar os pacientes com cada um dos três tipos de anomalia.

A implementação dos três novos descritores colaborou para um aumento significativamente do valor da AUC nos três casos, porém os resultados obtidos ainda podem ser considerados aquém do esperado.

Figura 23 – Gráfico da curva de Precisão *versus* Revocação dos pacientes diagnosticados como sem anomalia utilizando um vetor de 18 características. AUC obtida = 0,4813.

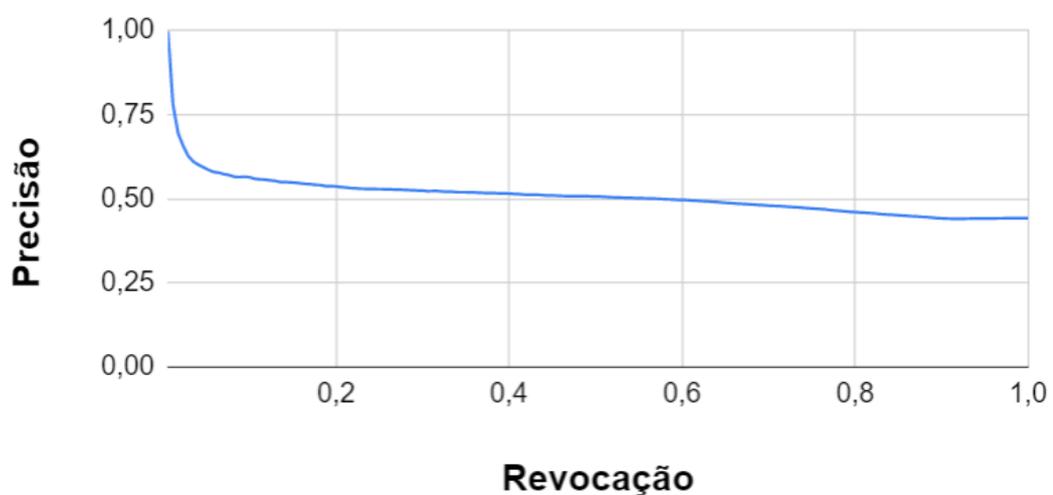
Precisão versus Revocação - Sem anomalia



Fonte – Pedro Henrique Morais Delmondes, 2022

Figura 24 – Gráfico da curva de Precisão *versus* Revocação dos pacientes diagnosticados com cardiomiopatia hipertrófica utilizando um vetor de 18 características. AUC obtida = 0,5086.

Precisão versus Revocação - Hipertróficos



Fonte – Pedro Henrique Morais Delmondes, 2022

Figura 25 – Gráfico da curva de Precisão *versus* Revocação dos pacientes diagnosticados com cardiomiopatia dilatada utilizando um vetor de 18 características. AUC obtida = 0,3367.



Fonte – Pedro Henrique Morais Delmondes, 2022

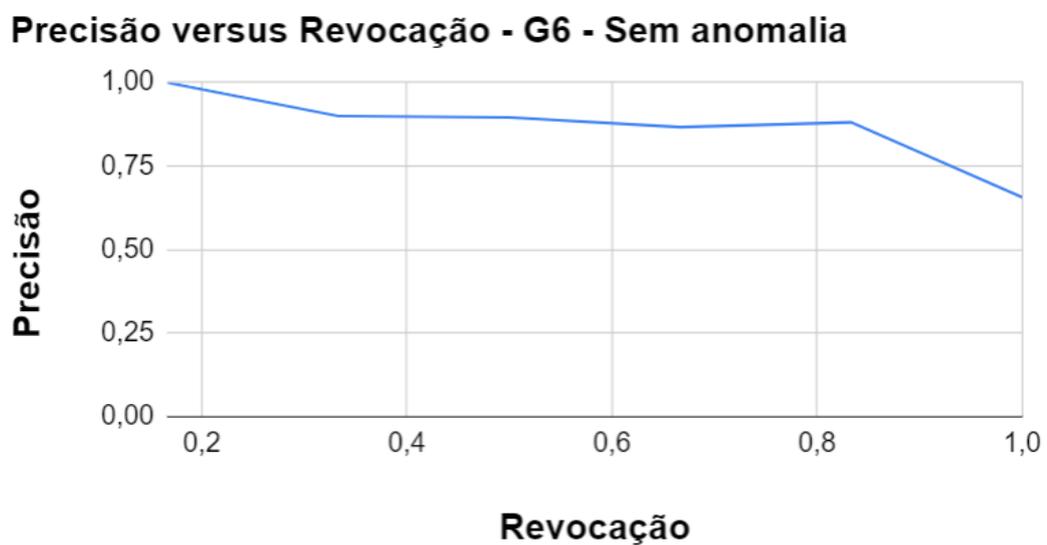
5.5 Recuperação de exames utilizando 18 características com estratificação da base de dados

Por último, levando em consideração que o ventrículo esquerdo pode variar de tamanho de acordo com o sexo e idade dos pacientes (KITZMAN; EDWARDS, 1990), fizeram-se a necessários novos testes com o conjunto de dados estratificados a fim de verificar se essas variações nas dimensões cardíacas poderiam influenciar o resultado do sistema. Dos 384 pacientes utilizados, 378 possuíam informações de sexo e idade e foram separados em oito grupos conforme a seguir:

- G1: pacientes do sexo masculino com idade ≤ 20 anos - 11 pacientes;
- G2: pacientes do sexo masculino com idade ≥ 21 anos e ≤ 41 anos - 114 pacientes;
- G3: pacientes do sexo masculino com idade ≥ 42 anos e ≤ 61 anos - 77 pacientes;
- G4: pacientes do sexo masculino com idade ≥ 62 anos - 59 pacientes;
- G5: pacientes do sexo feminino com idade ≤ 20 anos - 5 pacientes;
- G6: pacientes do sexo feminino com idade ≥ 21 anos e ≤ 41 anos - 31 pacientes;
- G7: pacientes do sexo feminino com idade ≥ 42 anos e ≤ 61 anos - 46 pacientes;
- G8: pacientes do sexo feminino com idade ≥ 62 anos - 35 pacientes.

Devido a diferença na quantidade de pacientes em cada grupo, os valores gerais de AUC foram calculados a partir de uma média entre as AUC obtidas nos gráficos de Precisão *versus* Revocação de cada grupo, os valores de AUC de cada grupo e média geral são apresentados na tabela 3. Como exemplo, apresentamos os gráficos de Precisão *versus* Revocação (figuras 26, 27 e 28) obtidos na recuperação dos pacientes do grupo G6, devido a este grupo possuir quantidade significativa de pacientes em cada um dos casos abordados.

Figura 26 – Gráfico da curva de Precisão *versus* Revocação dos pacientes do grupo G6 diagnosticados como sem anomalia. AUC obtida = 0,86667.



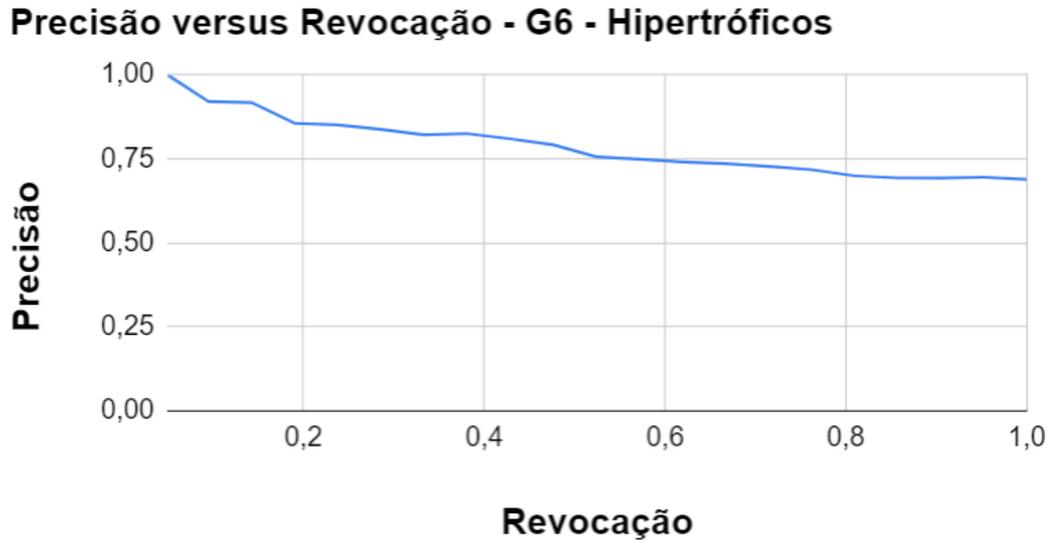
Fonte – Pedro Henrique Morais Delmondes, 2022

Tabela 3 – Medidas de AUC obtidas em cada um dos conjuntos de pacientes estratificados.

Grupo	Sem anomalia	Hipertróficos	Dilatados
G1	1	0,87	N/A
G2	0,80	0,43	0,27
G3	0,70	0,64	0,43
G4	1	0,47	0,74
G5	N/A	1	N/A
G6	0,86	0,78	0,44
G7	0,61	0,60	0,49
G8	0,82	0,70	0,42
Média	0,83	0,69	0,46

Fonte – Pedro Henrique Morais Delmondes, 2022

Figura 27 – Gráfico da curva de Precisão *versus* Revocação dos pacientes do grupo G6 diagnosticados com cardiomiopatia hipertrófica. AUC obtida = 0,7871.



Fonte – Pedro Henrique Morais Delmondes, 2022

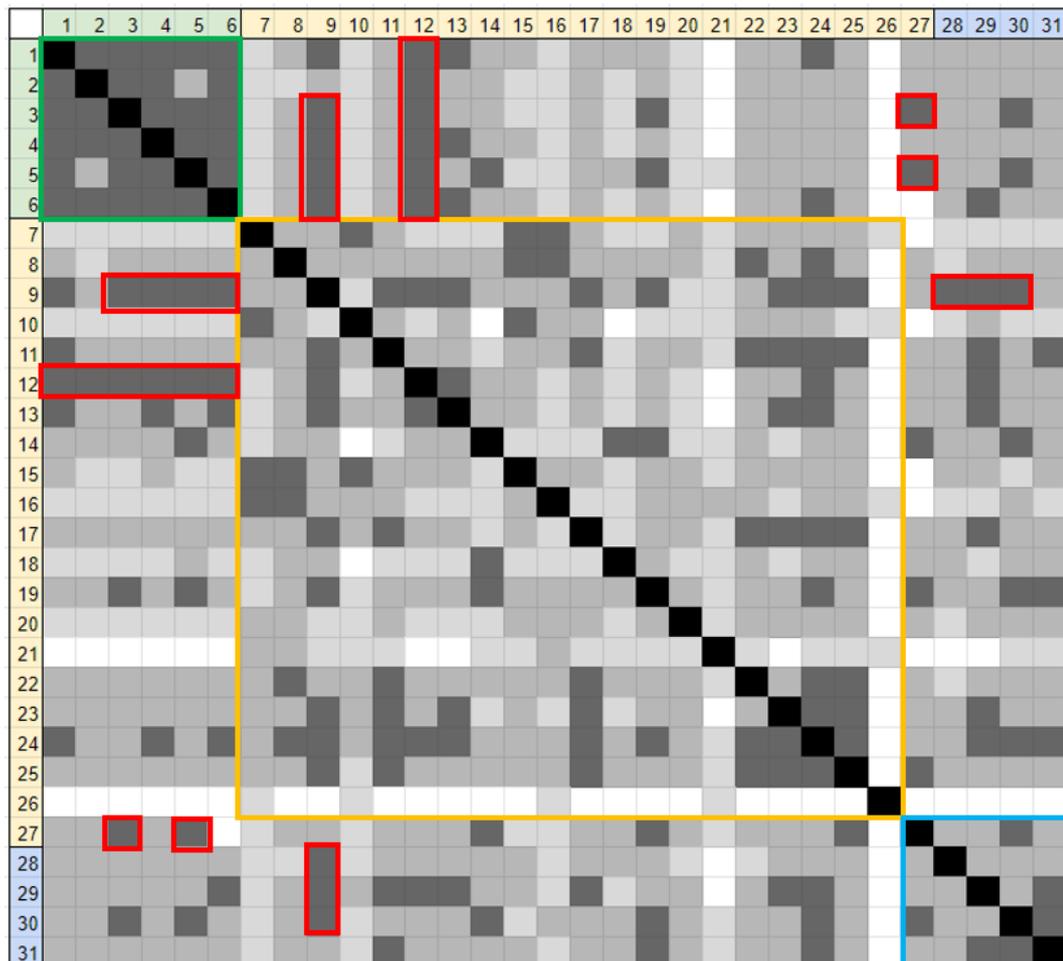
Figura 28 – Gráfico da curva de Precisão *versus* Revocação dos pacientes do grupo G6 diagnosticados com cardiomiopatia dilatada. AUC obtida = 0,4462.



Fonte – Pedro Henrique Morais Delmondes, 2022

Para a recuperação realizada no grupo G6, foi construída uma Matriz de Distâncias, apresentada na figura 29, onde casos considerados similares pela ferramenta possuem cor mais escura e as demais cores foram atribuídas de acordo com um critério de intervalo de similaridade. Na figura foram demarcados os agrupamentos onde, idealmente, espera-se que as tonalidades de preto e cinza sejam mais escuras, indicando maior similaridade entre os casos. Na figura foram demarcados em verde os casos diagnosticados como sem anomalia, em amarelo os casos diagnosticados com cardiomiopatia hipertrófica, em azul os casos de pacientes diagnosticados com cardiomiopatia dilatada e, em vermelho, alguns dos casos que foram recuperados indevidamente.

Figura 29 – Matriz de Distâncias obtida a partir dos resultados de recuperação dos pacientes do grupo G6.



Fonte – Pedro Henrique Morais Delmondes, 2022

Ao analisar a matriz de distâncias, pode-se observar que há uma concentração de exames recuperados corretamente no canto esquerdo superior, onde estão os exames sem anomalia enquanto para as outras classes não existe padrão de agrupamento, o que denota

erros na recuperação de exames de mesmo tipo. Para todos os tipos de paciente é possível observar erros de recuperação, uma vez que existem células coloridas com tons escuros de cinza em todas as nas outras classes (demarcados em vermelho), mesmo considerando apenas os pacientes sem anomalias.

Essa distribuição de cores observada na matriz corrobora os dados obtidos nos gráficos de Precisão *versus* Revocação e AUC, onde é possível observar, numericamente, que o desempenho da recuperação dos pacientes sem anomalia foi melhor que os dos pacientes com cardiomiopatia.

5.6 Análise geral do desempenho das abordagens

A tabela 4 contém a métrica de AUC do gráfico de Precisão *versus* Revocação para todos os experimentos e quadros clínicos. Adicionalmente incluiu-se o resultado obtido pela abordagem SBRF (Harmônicos esféricos utilizando redes de fluxo) no mesmo conjunto de dados utilizado neste trabalho, que foi apresentada em (BERGAMASCO; ROCHITTE; NUNES, 2018) que realiza a recuperação por conteúdo de objetos cardíacos 3D por meio do uso de harmônicos esféricos para extrair características e grafos para comparar diferentes exames.

Tabela 4 – Medidas de AUC obtidas em cada um dos experimentos.

Experimento	Sem anomalia	Hipertróficos	Dilatados
15 características	0,39	0,45	0,30
18 características	0,48	0,50	0,33
Média 18 características estratificado	0,83	0,69	0,46
SBRF estratificado	0,90	0,93	0,88

Fonte – Pedro Henrique Morais Delmondes, 2022

O desempenho superior da abordagem com 18 características em relação à de 15 características pode ser explicada pela falta de descritores que considerassem o epicárdio, utilizando o volume do miocárdio como um dos descritores. Deve-se levar em consideração que nas cardiomiopatias hipertrófica e dilatada, que afetam principalmente a espessura do miocárdio do ventrículo esquerdo comprometendo o movimento muscular durante o ciclo cardíaco, os descritores podem detectar uma anomalia no movimento, porém sem a

informação adicional sobre o miocárdio não possui informação suficiente para indicar um exame como paciente de cardiomiopatia hipertrófica ou dilatada.

Ao se estratificar o conjunto de dados, obteve-se um desempenho significativamente melhor na métrica de AUC média. O desempenho na recuperação de casos sem anomalia melhorou cerca de 75%, cerca de 45% nos casos clínicos de cardiomiopatia hipertrófica e 38% nos casos de cardiomiopatia dilatada. Essa melhoria claramente denota que os dados de idade e sexo dos pacientes não podem ser ignorados em abordagens de CBIR, uma vez que a anatomia do ventrículo esquerdo varia de acordo com esses parâmetros (KITZMAN; EDWARDS, 1990). Novos estudos podem ser realizados de modo a tornar os descritores desenvolvidos por esse trabalho invariantes à idade e sexo.

Dentro do escopo deste trabalho de pesquisa, não foi possível atingir os mesmos resultados obtidos na abordagem SBRF com o conjunto de dados estratificado, porém vale ressaltar que essa abordagem explora um paradigma diferente de CBIR já mais maduro: o de recuperação de modelos tridimensionais. Ainda existem espaços a serem explorados na abordagem *multi-slice* e *multi-frame*.

Um fato que pode ter comprometido de forma geral o desempenho dos experimentos aqui apresentados é o da segmentação semi-automática fornecida pelo *software Segment*. Dado que diversas imagens cardíacas foram incorretamente segmentadas conforme exposto na seção 5.1. Esse tipo de problema na segmentação reduz a quantidade de informação que os descritores conseguem obter para calcular a variação da área de um *frame* para o outro, afetando negativamente o cálculo das características de de C1 a C15.

5.7 Considerações finais do capítulo

No presente capítulo foram apresentados e discutidos os resultados obtidos na utilização dos métodos e técnicas propostos e descritos no capítulo 4. De maneira geral, somente os resultados obtidos com o conjunto de dados estratificado para casos sem anomalia, foram satisfatórios. Porém diversas abordagens que não faziam parte do escopo deste projeto ainda podem ser aplicadas em trabalhos futuros (6.2). No capítulo final deste projeto serão apresentadas as conclusões do trabalho, trabalhos futuros e as contribuições deste projeto de pesquisa.

6 Conclusão

Este projeto de pesquisa propôs o desenvolvimento de um sistema CAD baseado em CBIR que utilizasse descritores do tipo *multi-slice* e *multi-frame* para auxílio ao diagnóstico de cardiomiopatias. Resultados obtidos em uma revisão bibliográfica sistemática indicam que a utilização desse tipo de descritor ainda é incipiente na literatura e, além disso, os resultados obtidos nesta implementação mostram que ainda há potencial a ser explorado nesse tipo de abordagem, especialmente nos itens que serão citados na seção 6.2.

Para se atingir o objetivo proposto, 384 exames de MRI foram segmentados de forma semi-automática por meio da ferramenta *Segment*, 18 novos descritores que levam em conta todos os *slices* de um exame de MRI em todo o ciclo cardíaco foram elaborados e implementados, esses descritores foram organizados na forma de um vetor de características, o que permitiu com que fosse comparados entre si e a tarefa de recuperação dos exames mais similares fosse realizada. O desempenho geral dessa abordagem foi avaliado por meio da AUC de gráficos de Precisão *versus* Revocação, e Matriz de Distâncias.

Durante os experimentos, foi verificada a influência da qualidade da segmentação e como cada tipo de descritor influencia no resultado final da tarefa de recuperação. Destacou-se a importância, nesta aplicação para detecção de cardiomiopatias, de se utilizar descritores que considerem o volume do miocárdio e não somente o movimento do endocárdio. Destacou-se também a necessidade de se levar em conta a idade e gênero dos pacientes utilizados no conjunto de dados de teste, uma vez que a anatomia de cada ventrículo esquerdo pode variar de acordo com o sexo e a idade.

Por fim, espera-se que os descritores desenvolvidos sejam integrados a outras ferramentas de modo a criar um sistema CAD completo e robusto. O desenvolvimento de tais ferramentas são fundamentais para diminuir o tempo e custo de análise de exames de MRI e também para a definição de um diagnóstico preciso mais rapidamente, gerando impacto positivo para especialistas médicos e pacientes.

6.1 Trabalhos futuros

Conforme mencionado na seção 5.1, os descritores implementados se utilizam de medidas geométricas obtidas a partir da segmentação e, com isso, se tornam sensíveis

a qualquer anormalidade, imperfeição ou imprecisão que se apresente na geometria do contorno endocárdio e epicárdio. Recentemente, no LApIS, um novo método de segmentação automática baseada em CNNs e Modelos Deformáveis (RIBEIRO; NUNES, 2022) foi desenvolvido, esse método poderá prover imagens segmentadas com contornos do endocárdio e epicárdio com qualidade superior à do *Segment, utilizado nesse trabalho*, para os descritores.

Visando aperfeiçoar a entrada da segmentação utilizada para calcular os descritores, testes podem ser realizados calculando o perímetro do endocárdio e epicárdio em milímetros ao invés de número de pixels.

Após o cálculo dos vetores de características, técnicas de Aprendizado de Máquina para classificar pacientes quanto a existência ou não de cardiomiopatias. Possíveis candidatas são as técnicas de Redes Neurais e SVMs. Tais técnicas normalmente são utilizadas em conjunto com métodos de redução de dimensionalidade como o algoritmo de seleção de características *Relief*, utilizado neste trabalho. Porém há ainda a opção de utilizar métodos de fusão de características como a Análise de Componentes Principais (PCA), que podem ser utilizados alternativamente e ter seu desempenho comparado.

Nesta implementação apenas a distância Euclidiana foi utilizada como medida de similaridade entre os vetores de características de cada exame. Porém existem diferentes funções de distância que podem ser testadas quanto à sua adequação ao problema estudado, como a distância *Manhattan*, distância *Hausdorff* e distância *Canberra*.

6.2 Contribuições

O desenvolvimento deste projeto interdisciplinar resultou em contribuições para as áreas da Medicina e da Computação:

- Uma revisão sistemática que explora diferentes descritores, métodos de comparação, bases de dados e técnicas de avaliação existentes foi publicada em uma revista de alto impacto. Dessa forma, irá auxiliar pesquisadores a terem uma visão completa do estado da arte da área, limitações atuais e oportunidades;
- A segmentação semi-automática de mais de 380 ventrículos esquerdos foi realizada e será disponibilizada para que futuros pesquisadores da área possam utilizar e realizar testes comparativos entre diferentes abordagens de CBIR;

- Neste trabalho de pesquisa um novo paradigma de sistemas CBIR foi explorado, extraindo características do conjunto de *slices* (*multi-slice*) e do conjunto de *frames* (*multi-frame*) de exames de Ressonância Magnética a fim de compará-los e classificá-los quanto a existência de cardiomiopatias, expandindo a fronteira de conhecimento da utilização de sistemas de auxílio ao diagnóstico médico de cardiomiopatias;

Referências

- ACM. Association for Computer Machinery (ACM) Digital Library. 2020. Disponível em: <https://dl.acm.org>. Citado na página 29.
- ALBANESI, F.; MANES, F. Cardiomiopatias. Arquivos Brasileiros de Cardiologia, SciELO Brasil, v. 71, n. 2, p. 95–107, 1998. Citado na página 21.
- ALTABELLA, L.; BORRAZZO, C.; CARNÌ, M.; GALEA, N.; FRANCONI, M.; FIORELLI, A.; CASTRO, E. D.; CATALANO, C.; CARBONE, I. A feasible and automatic free tool for t1 and ecv mapping. Physica Medica, Elsevier, v. 33, p. 47–55, 2017. Citado 2 vezes nas páginas 33 e 36.
- AMAN, J. M.; YAO, J.; SUMMERS, R. M. Content-based image retrieval on ct colonography using rotation and scale invariant features and bag-of-words model. In: 2010 IEEE International Symposium on Biomedical Imaging: From Nano to Macro. [S.l.: s.n.], 2010. p. 1357–1360. Citado na página 17.
- ANDREOPOULOS, A.; TSOTSOS, J. K. Efficient and generalizable statistical models of shape and appearance for analysis of cardiac mri. Medical Image Analysis, Elsevier, v. 12, n. 3, p. 335–357, 2008. Citado 2 vezes nas páginas 40 e 41.
- BERGAMASCO, L. C. C. Recuperação de imagens cardíacas tridimensionais por conteúdo. Tese (Doutorado) — Universidade de São Paulo, 2013. Citado na página 17.
- BERGAMASCO, L. C. C.; LIMA, K. R.; ROCHITTE, C. E.; NUNES, F. L. A bipartite graph approach to retrieve similar 3d models with different resolution and types of cardiomyopathies. Expert Systems with Applications, Elsevier, v. 193, p. 116422, 2022. Citado na página 24.
- BERGAMASCO, L. C. C.; ROCHITTE, C. E.; NUNES, F. L. 3d medical objects processing and retrieval using spherical harmonics: a case study with congestive heart failure mri exams. In: Proceedings of the 33rd Annual ACM Symposium on Applied Computing. [S.l.: s.n.], 2018. p. 22–29. Citado 3 vezes nas páginas 17, 24 e 66.
- BERNARD, O.; LALANDE, A.; ZOTTI, C.; CERVENANSKY, F.; YANG, X.; HENG, P.-A.; CETIN, I.; LEKADIR, K.; CAMARA, O.; BALLESTER, M. A. G. *et al.* Deep learning techniques for automatic mri cardiac multi-structures segmentation and diagnosis: is the problem solved? IEEE transactions on medical imaging, ieee, v. 37, n. 11, p. 2514–2525, 2018. Citado na página 45.
- BOGAERT, J.; DYMARKOWSKI, S.; TAYLOR, A. M.; MUTHURANGU, V. Clinical cardiac MRI. [S.l.]: Springer Science & Business Media, 2012. Citado na página 22.
- BOLLACHE, E.; REDHEUIL, A.; CLÉMENT-GUINAUDEAU, S.; DEFRANCE, C.; PERDRIX, L.; LADOUCEUR, M.; LEFORT, M.; CESARE, A. D.; HERMENT, A.; DIEBOLD, B. *et al.* Automated left ventricular diastolic function evaluation from phase-contrast cardiovascular magnetic resonance and comparison with doppler echocardiography. Journal of Cardiovascular Magnetic Resonance, Springer, v. 12, n. 1, p. 1–11, 2010. Citado 2 vezes nas páginas 33 e 36.

CHENOUNE, Y.; PELLOT-BARAKAT, C.; CONSTANTINIDES, C.; BERBARI, R. E.; LEFORT, M.; ROULLOT, E.; MOUSSEAU, E.; FROUIN, F. Methodology for jointly assessing myocardial infarct extent and regional contraction in 3-d cmri. IEEE transactions on biomedical engineering, IEEE, v. 59, n. 9, p. 2650–2659, 2012. Citado 3 vezes nas páginas 33, 36 e 39.

CHETHAN, K.; BHANDARKAR, R. Hybrid feature extraction technique on brain mri images for content-based image retrieval of alzheimer’s disease. In: Advances in Communication, Signal Processing, VLSI, and Embedded Systems. [S.l.]: Springer, 2020. p. 127–141. Citado na página 15.

DASH, S.; SHAKYAWAR, S. K.; SHARMA, M.; KAUSHIK, S. Big data in healthcare: management, analysis and future prospects. Journal of Big Data, SpringerOpen, v. 6, n. 1, p. 1–25, 2019. Citado na página 16.

DEKHIL, O.; TAHER, F.; KHALIFA, F.; BEACHE, G.; ELMAGHRABY, A.; EL-BAZ, A. A novel fully automated cad system for left ventricle volume estimation. In: IEEE. 2018 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT). [S.l.], 2018. p. 602–606. Citado 6 vezes nas páginas 32, 33, 35, 36, 39 e 48.

DELMONDES, P. H. M.; BERGAMASCO, L. C. C.; NUNES, F. d. L. dos S. Recuperação de modelos médicos por conteúdo usando extrator local de área e distância. Revista de Informática Teórica e Aplicada, v. 22, n. 2, p. 10–30, 2015. Citado na página 17.

DELMONDES, P. H. M.; NUNES, F. L. S. A systematic review of multi-slice and multi-frame descriptors in cardiac mri exams. Computer Methods and Programs in Biomedicine, v. 221, p. 106889, 2022. ISSN 0169-2607. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0169260722002711>. Citado 3 vezes nas páginas 29, 38 e 47.

DOI, K. Computer-aided diagnosis in medical imaging: historical review, current status and future potential. Computerized medical imaging and graphics, Elsevier, v. 31, n. 4-5, p. 198–211, 2007. Citado 2 vezes nas páginas 15 e 22.

DU, X.; TANG, R.; YIN, S.; ZHANG, Y.; LI, S. Direct segmentation-based full quantification for left ventricle via deep multi-task regression learning network. IEEE journal of biomedical and health informatics, IEEE, v. 23, n. 3, p. 942–948, 2018. Citado 4 vezes nas páginas 33, 36, 39 e 45.

EFTESTØL, T.; WOIE, L.; ENGAN, K.; KVALØY, J. T.; NILSEN, D. W.; ØRN, S. Texture analysis to assess risk of serious arrhythmias after myocardial infarction. In: IEEE. 2012 Computing in Cardiology. [S.l.], 2012. p. 365–368. Citado 3 vezes nas páginas 33, 35 e 36.

ELNAKIB, A.; BEACHE, G. M.; GIMEL’FARB, G.; EL-BAZ, A. Intramyocardial strain estimation from cardiac cine mri. International journal of computer assisted radiology and surgery, Springer, v. 10, n. 8, p. 1299–1312, 2015. Citado 3 vezes nas páginas 33, 36 e 39.

ELSEVIER. Science Direct. 2020. Disponível em: <https://www.sciencedirect.com>. Citado na página 29.

ELSEVIER. Scopus. 2020. Disponível em: <https://www.scopus.com/search/form.uri>. Citado na página 29.

FLORACK, L.; ASSEN, H. van; SUINESIAPUTRA, A. Dense multiscale motion extraction from cardiac cine mr tagging using harp technology. In: IEEE. 2007 IEEE 11th International Conference on Computer Vision. [S.l.], 2007. p. 1–8. Citado 4 vezes nas páginas 33, 35, 36 e 38.

FRIEDRICH, M. G.; SECHTEM, U.; SCHULZ-MENGER, J.; HOLMVANG, G.; ALAKIJA, P.; COOPER, L. T.; WHITE, J. A.; ABDEL-ATY, H.; GUTBERLET, M.; PRASAD, S. *et al.* Cardiovascular magnetic resonance in myocarditis: A jacc white paper. Journal of the American College of Cardiology, American College of Cardiology Foundation Washington, DC, v. 53, n. 17, p. 1475–1487, 2009. Citado na página 16.

GIGER, M. L. Machine learning in medical imaging. Journal of the American College of Radiology, Elsevier, v. 15, n. 3, p. 512–520, 2018. Citado na página 15.

GOYAL, A.; BATHLA, D.; VENKATA, S. D. P. M. L.; HOSSAIN, G.; CHALLOO, R.; DUBEY, A. K.; BHAN, A.; RANJAN, P. *et al.* A graphical computational tool for computerized ventricular extraction in magnetic resonance cardiac imaging. In: Soft Computing and Signal Processing. [S.l.]: Springer, 2019. p. 1–11. Citado 4 vezes nas páginas 33, 35, 36 e 39.

HALL, J. E.; HALL, M. E. Guyton and Hall textbook of medical physiology e-Book. 14. ed. [S.l.]: Elsevier Health Sciences, 2020. Citado na página 19.

HAMILTON, B. A. Data science bowl cardiac challenge data. 2014. Citado 3 vezes nas páginas 40, 41 e 45.

IEEE. IEEE Xplore Digital Library. 2020. Disponível em: <https://ieeexplore.ieee.org/Xplore/home.jsp>. Citado na página 29.

ISSA, N. T.; BYERS, S. W.; DAKSHANAMURTHY, S. Big data: the next frontier for innovation in therapeutics and healthcare. Expert review of clinical pharmacology, Taylor & Francis, v. 7, n. 3, p. 293–298, 2014. Citado na página 15.

JÚNIOR, E. A.; YAMASHITA, H. Aspectos básicos de tomografia computadorizada e ressonância magnética. Brazilian Journal of Psychiatry, SciELO Brasil, v. 23, p. 2–3, 2001. Citado na página 21.

KHALIFA, F.; BEACHE, G. M.; GIMEL’FARB, G.; EL-BAZ, A. A novel approach for accurate estimation of left ventricle global indexes from short-axis cine mri. In: IEEE. 2011 18th IEEE International Conference on Image Processing. [S.l.], 2011. p. 2645–2648. Citado 7 vezes nas páginas 32, 33, 36, 39, 41, 42 e 48.

KIRA, K.; RENDELL, L. A. A practical approach to feature selection. In: Machine learning proceedings 1992. [S.l.]: Elsevier, 1992. p. 249–256. Citado na página 25.

KITZMAN, D. W.; EDWARDS, W. D. Age-related changes in the anatomy of the normal human heart. Journal of gerontology, The Gerontological Society of America, v. 45, n. 2, p. M33–M39, 1990. Citado 2 vezes nas páginas 62 e 67.

KNIGHT, W. DARPA is funding projects that will try to open up AI’s black boxes. [S.l.]: MIT Technology Review. Retrieved, 2017. Citado na página 38.

KURZENDORFER, T.; BREININGER, K.; STEIDL, S.; BROST, A.; FORMAN, C.; MAIER, A. Myocardial scar segmentation in lge-mri using fractal analysis and random forest classification. In: IEEE. 2018 24th International Conference on Pattern Recognition (ICPR). [S.l.], 2018. p. 3168–3173. Citado 3 vezes nas páginas [33](#), [35](#) e [36](#).

LI, T.; WEI, B.; CONG, J.; HONG, Y.; LI, S. Direct estimation of left ventricular ejection fraction via a cardiac cycle feature learning architecture. Computers in biology and medicine, Elsevier, v. 118, p. 103659, 2020. Citado 6 vezes nas páginas [33](#), [36](#), [38](#), [39](#), [45](#) e [48](#).

LU, Y.; RADAU, P.; CONNELLY, K.; DICK, A.; WRIGHT, G. Pattern recognition of abnormal left ventricle wall motion in cardiac mr. In: SPRINGER. International Conference on Medical Image Computing and Computer-Assisted Intervention. [S.l.], 2009. p. 750–758. Citado 3 vezes nas páginas [32](#), [33](#) e [36](#).

LUO, G.; DONG, S.; WANG, K.; ZHANG, H. Cardiac left ventricular volumes prediction method based on atlas location and deep learning. In: IEEE. 2016 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). [S.l.], 2016. p. 1604–1610. Citado 6 vezes nas páginas [32](#), [33](#), [35](#), [36](#), [39](#) e [41](#).

MANTILLA, J. J.; PAREDES, J. L.; BELLANGER, J.-J.; DONAL, E.; LECLERCQ, C.; GARREAU, M. Discriminative dictionary learning for local lv wall motion classification in cardiac mri. Expert systems with applications, Elsevier, v. 129, p. 286–295, 2019. Citado 4 vezes nas páginas [32](#), [33](#), [36](#) e [41](#).

MARIEB, E. N.; WILHELM, P. B.; MALLATT, J. *et al.* Human anatomy. [S.l.]: Benjamin Cummings, 2014. Citado 2 vezes nas páginas [8](#) e [20](#).

MCROBBIE, D.; MOORE, E.; GRAVES, M.; PRINCE, M. Mri from picture to proton. Ohmsha, Ltd, Am Soc Neuroradiology, 2004. Citado na página [22](#).

MESSADI, M.; BESSAID, A.; MARIANO-GOULART, D.; BOUALLÈGUE, F. B. Development and clinical validation of a hybrid method for semiautomated left ventricle endocardial and epicardial boundary extraction on cine-magnetic resonance images. Journal of Medical Imaging, International Society for Optics and Photonics, v. 5, n. 2, p. 024002, 2018. Citado 6 vezes nas páginas [32](#), [33](#), [35](#), [36](#), [41](#) e [44](#).

MISHRA, A.; DUTTA, P.; GHOSH, M. Fuzzy shape based motion evaluation of left ventricle using genetic algorithm. Image and Vision Computing, Elsevier, v. 24, n. 5, p. 436–446, 2006. Citado 3 vezes nas páginas [33](#), [35](#) e [36](#).

MORENO, A.; RODRIGUEZ, J.; MARTÍNEZ, F. Regional multiscale motion representation for cardiac disease prediction. In: IEEE. 2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA). [S.l.], 2019. p. 1–5. Citado 11 vezes nas páginas [25](#), [32](#), [33](#), [35](#), [36](#), [38](#), [39](#), [41](#), [44](#), [45](#) e [48](#).

MÜLLER, A.; MERKLE, N.; HOMBACH, V.; GREBE, O.; NUSSER, T.; WÖHRLE, J.; BINNER, L.; KESTLER, H. Extracting robust features from cardiac magnetic resonance image contours for detecting dilated cardiomyopathy. In: IEEE. Computers in Cardiology, 2004. [S.l.], 2004. p. 157–160. Citado 4 vezes nas páginas [33](#), [35](#), [36](#) e [43](#).

- MURALA, S.; WU, Q. J. Mri and ct image indexing and retrieval using local mesh peak valley edge patterns. Signal processing: image communication, Elsevier, v. 29, n. 3, p. 400–409, 2014. Citado na página 17.
- NACHTOMY, E.; COOPERSTEIN, R.; VATURI, M.; BOSAK, E.; VERED, Z.; AKSELROD, S. Automatic assessment of cardiac function from short-axis mri: procedure and clinical evaluation. Magnetic resonance imaging, Elsevier, v. 16, n. 4, p. 365–376, 1998. Citado 4 vezes nas páginas 32, 33, 35 e 36.
- NACIF, M. S.; JUNIOR, A. C. d. O.; CARVALHO, A. C. P.; ROCHITTE, C. E. Ressonância magnética cardíaca e seus planos anatômicos: como eu faço? Arquivos Brasileiros de Cardiologia, SciELO Brasil, v. 95, n. 6, p. 756–763, 2010. Citado na página 22.
- NAGESWARARAO, A.; SRINIVASAN, S. A framework on automated ventricular analysis of cmr images. In: IEEE. 2017 Trends in Industrial Measurement and Automation (TIMA). [S.l.], 2017. p. 1–6. Citado 4 vezes nas páginas 33, 35, 36 e 39.
- NAJMAN, L.; COUSTY, J.; COUPRIE, M.; TALBOT, H.; CLÉMENT-GUINAUDEAU, S.; GOISSEN, T.; GAROT, J. An open, clinically-validated database of 3d+ t cine-mr images of the left ventricle with associated manual and automated segmentations. Insight Journal, 2007. Citado 2 vezes nas páginas 40 e 41.
- NASR-ESFAHANI, M.; MOHREKESH, M.; AKBARI, M.; SOROSHMEHR, S. R.; NASR-ESFAHANI, E.; KARIMI, N.; SAMAVI, S.; NAJARIAN, K. Left ventricle segmentation in cardiac mr images using fully convolutional network. In: IEEE. 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). [S.l.], 2018. p. 1275–1278. Citado 2 vezes nas páginas 15 e 24.
- NCBI. Pubmed. National Center for Biotechnology Information (NCBI), U.S. National Library of Medicine, National Institutes of Health. 2020. Disponível em: <https://www.ncbi.nlm.nih.gov/pubmed>. Citado na página 29.
- NEISIUS, U.; EL-REWAIDY, H.; NAKAMORI, S.; RODRIGUEZ, J.; MANNING, W. J.; NEZAFAT, R. Radiomic analysis of myocardial native t1 imaging discriminates between hypertensive heart disease and hypertrophic cardiomyopathy. JACC: Cardiovascular Imaging, American College of Cardiology Foundation Washington, DC, v. 12, n. 10, p. 1946–1954, 2019. Citado 6 vezes nas páginas 33, 35, 36, 39, 40 e 43.
- ORGANIZAÇÃO MUNDIAL DA SAÚDE. The top 10 causes of death. 2020. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>. Citado na página 15.
- PARAGES, F. M.; BRANKOV, J. G. Detection of cardiac abnormalities from mri sequences by using a deformable mesh model. In: 2012 IEEE Nuclear Science Symposium and Medical Imaging Conference Record (NSS/MIC). [S.l.: s.n.], 2012. Citado 5 vezes nas páginas 32, 33, 35, 36 e 45.
- RADAU, P.; LU, Y.; CONNELLY, K.; PAUL, G.; DICK, A.; WRIGHT, G. Evaluation framework for algorithms segmenting short axis cardiac mri. The MIDAS Journal-Cardiac MR Left Ventricle Segmentation Challenge, v. 49, 2009. Citado 5 vezes nas páginas 8, 23, 40, 41 e 44.

RIBEIRO, M. A.; NUNES, F. L. Segmentação do ventrículo esquerdo em exames de ressonância magnética cardíaca com aprendizado profundo e modelos deformáveis contendo restrições de forma. In: SBC. Anais Estendidos do XVIII Simpósio Brasileiro de Sistemas de Informação. [S.l.], 2022. p. 113–126. Citado na página 69.

RIBEIRO, M. A. d. O. Segmentação automática do ventrículo esquerdo em exames de Ressonância Magnética Cardíaca. Tese (Doutorado) — Universidade de São Paulo, 2020. Citado 2 vezes nas páginas 8 e 20.

RIBEIRO, M. A. d. O. Segmentação do ventrículo esquerdo em exames de ressonância magnética cardíaca com aprendizado profundo e modelos deformáveis contendo restrições de forma. Tese (Doutorado) — Universidade de São Paulo, 2021. Citado na página 44.

ROHÉ, M.-M.; SERMESANT, M.; PENNEC, X. Low-dimensional representation of cardiac motion using barycentric subspaces: a new group-wise paradigm for estimation, analysis, and reconstruction. Medical image analysis, Elsevier, v. 45, p. 1–12, 2018. Citado 2 vezes nas páginas 33 e 36.

SANZ-ESTÉBANEZ, S.; CORDERO-GRANDE, L.; SEVILLA, T.; REVILLA-ORODEA, A.; LUIS-GARCÍA, R. de; MARTÍN-FERNÁNDEZ, M.; ALBEROLA-LÓPEZ, C. Vortical features for myocardial rotation assessment in hypertrophic cardiomyopathy using cardiac tagged magnetic resonance. Medical image analysis, Elsevier, v. 47, p. 191–202, 2018. Citado 4 vezes nas páginas 32, 33, 35 e 36.

SARMIENTO, E.; PICO, J.; MARTINEZ, F. Cardiac disease prediction from spatio-temporal motion patterns in cine-mri. In: IEEE. 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018). [S.l.], 2018. p. 1305–1308. Citado 11 vezes nas páginas 15, 25, 32, 33, 36, 38, 39, 41, 44, 45 e 48.

TAN, C.; ZHANG, Z.; YANG, X.; YI, J. Cardiac image registration by combining point set matching with surface structure features. In: IEEE. 2016 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). [S.l.], 2016. p. 395–402. Citado 4 vezes nas páginas 33, 35, 36 e 41.

TOBON-GOMEZ, C.; CRAENE, M. D.; MCLEOD, K.; TAUTZ, L.; SHI, W.; HENNEMUTH, A.; PRAKOSA, A.; WANG, H.; CARR-WHITE, G.; KAPETANAKIS, S. *et al.* Benchmarking framework for myocardial tracking and deformation algorithms: An open access database. Medical image analysis, Elsevier, v. 17, n. 6, p. 632–648, 2013. Citado 2 vezes nas páginas 40 e 41.

TORRES, R. da S.; FALCAO, A. X. Content-based image retrieval: theory and applications. RITA, v. 13, n. 2, p. 161–185, 2006. Citado na página 24.

TUFVESSON, J.; HEDSTRÖM, E.; STEDING-EHRENBORG, K.; CARLSSON, M.; ARHEDEN, H.; HEIBERG, E. Validation and development of a new automatic algorithm for time resolved segmentation of the left ventricle in magnetic resonance imaging. Journal of Cardiovascular Magnetic Resonance, BioMed Central, v. 17, n. 1, p. 1–3, 2015. Citado 4 vezes nas páginas 15, 24, 48 e 49.

WANG, W.; WANG, Y.; WU, Y.; LIN, T.; LI, S.; CHEN, B. Quantification of full left ventricular metrics via deep regression learning with contour-guidance. IEEE Access, IEEE, v. 7, p. 47918–47928, 2019. Citado 4 vezes nas páginas 33, 36, 39 e 45.

XING, F.; WOO, J.; GOMEZ, A. D.; PHAM, D. L.; BAYLY, P. V.; STONE, M.; PRINCE, J. L. Phase vector incompressible registration algorithm for motion estimation from tagged magnetic resonance images. IEEE transactions on medical imaging, IEEE, v. 36, n. 10, p. 2116–2128, 2017. Citado 3 vezes nas páginas 33, 36 e 41.

XU, C.; HOWEY, J.; OHORODNYK, P.; ROTH, M.; ZHANG, H.; LI, S. Segmentation and quantification of infarction without contrast agents via spatiotemporal generative adversarial learning. Medical image analysis, Elsevier, v. 59, p. 101568, 2020. Citado 5 vezes nas páginas 33, 36, 42, 44 e 45.

XUE, W.; ISLAM, A.; BHADURI, M.; LI, S. Direct multitype cardiac indices estimation via joint representation and regression learning. IEEE transactions on medical imaging, IEEE, v. 36, n. 10, p. 2057–2067, 2017. Citado 3 vezes nas páginas 33, 36 e 45.

Apêndices

Apêndice A – Protocolo de revisão bibliográfica sistemática

Objetivo:

Identificar na literatura descritores, e outros aspectos relacionados a eles, que considerem o conjunto de *slíces* de uma Ressonância Magnética cardíaca e analisá-los.

Questões de pesquisa:

Quais descritores de características consideram o conjunto de *slíces* de um exame de Ressonância Magnética?

Quais desses descritores foram aplicados na identificação de cardiomiopatias?

Quais *datasets* foram utilizados para avaliar os descritores?

Quais métricas são normalmente utilizadas para medir o desempenho de descritores de características?

Intervenção:

Métodos de descrição de características.

Controle:

1. E. Sarmiento, J. Pico and F. Martinez, "Cardiac disease prediction from spatio-temporal motion patterns in cine-MRI," 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), Washington, DC, 2018, pp. 1305-1308.
2. F. Khalifa, G. M. Beache, G. Gimel'farb and A. El-Baz, "A novel approach for accurate estimation of left ventricle global indexes from short-axis cine MRI," 2011 18th IEEE International Conference on Image Processing, Brussels, 2011, pp. 2645-2648.
3. F. M. Parages and J. G. Brankov, "Detection of cardiac abnormalities from MRI sequences by using a deformable mesh model," 2012 IEEE Nuclear Science Symposium and Medical Imaging Conference Record (NSS/MIC), Anaheim, CA, 2012, pp. 4028-4031. doi: 10.1109/NSSMIC.2012.6551921
4. M.-M. Rohé, M. Sermesant, X. Pennec, "Low-dimensional representation of cardiac motion using Barycentric Subspaces: A new group-wise paradigm for estimation analysis and reconstruction", *Med. Image Anal.*, vol. 45, pp. 1-12, Apr. 2018.

População:

Sistemas de Auxílio ao Diagnóstico (CAD) e ferramentas que utilizam descritores de características 2D para identificação de cardiomiopatias a partir de exames de Ressonância Magnética.

Resultados:

Visão do estado-da-arte de descritores 2D existentes que extraem características de exames de Ressonância Magnética.

Aplicação:

Pesquisadores da área de Informática Aplicada à Saúde interessados no desenvolvimento de sistemas CAD para identificar cardiomiopatias.

Seleção de fontes:

Serão considerados nesta revisão trabalhos que estejam publicados em anais de conferência ou em periódicos científicos. Esses trabalhos devem estar completamente disponíveis em bases eletrônicas indexadas e bibliotecas digitais online.

Palavras-chave e *Strings* de busca:

(MRI OR cine-mri OR "magnetic resonance")
AND (cardiology OR cardiac OR heart OR "left ventricle")
AND (characteristic OR feature OR shape)
AND (extraction OR descriptor)

e

(MRI OR cine-mri OR "magnetic resonance")
AND (cardiology OR cardiac OR heart OR "left ventricle")
AND (characteristic OR feature OR shape OR index OR indices OR biomarker)
AND (extraction OR descriptor)

Listagem de fontes:

Biblioteca digital do IEEE
Biblioteca digital da ACM
SCOPUS
PubMed
ScienceDirect

Tipo dos artigos:

Serão considerados artigos completos que estejam publicados em periódicos ou conferências com revisão por pares. *Short Papers* também serão considerados, desde que possuam resultados finais.

Idioma dos artigos:

Inglês

Crítérios de Inclusão dos Artigos:

1. Trabalhos que apresentam ou aplicam métodos de extração de características do ventrículo esquerdo em exames de Ressonância Magnética cardíaca;
2. Trabalhos que aplicam ou avaliam métodos de extração de características para identificar cardiomiopatias

Crítérios de Exclusão dos Artigos:

1. Trabalhos que não apresentam métodos de descrição de características a partir de exames médicos;
2. Trabalhos que apresentam métodos de descrição de características a partir de exames que não são Ressonância Magnética;
3. Trabalhos que aplicam métodos de extração de características em estruturas que não sejam o ventrículo esquerdo cardíaco;
4. Trabalhos que apresentam métodos de segmentação de exames de Ressonância Magnética que não utilizam as características da imagem para fazê-la;
5. Trabalhos que apresentam métodos de reconstrução de modelos 3D a partir de exames de Ressonância Magnética ou de extração de características de modelos 3D;
6. Trabalhos que estão em formato de *short paper* e ainda sem resultados finais;
7. Trabalhos que realizam extração de características em uma abordagem *blackbox*.

Crítérios de qualidade dos estudos primários:

Para avaliar os artigos serão considerados os seguintes critérios:

1. A descrição do método é apresentada claramente?
2. O resumo contém toda a informação relevante?
3. Tipo de benchmark utilizado;
4. Natureza do benchmark utilizado;
5. Tamanho do benchmark.

Processo de seleção dos estudos primários:

Esse processo será conduzido através de buscas em bases de dados eletrônicas relacionadas à Ciência da Computação, Informática Aplicada à Saúde e similares.

A *string* de busca será aplicada considerando o título, resumo e palavras-chave de cada base de dados.

Como primeiro passo, o título e resumo do artigo será avaliado para determinar sua relevância segundo a aplicação dos critérios de inclusão e exclusão. Se necessário, outras partes do artigo serão avaliadas (introdução, conclusão e metodologia, nessa ordem) para determinar se o artigo deve ser incluído.

Estratégia de extração de informação:

Será preenchido um formulário de extração de dados para cada texto considerado válido na Revisão Sistemática, esse formulário será preenchido de acordo com as informações extraídas pelo pesquisador durante a leitura completa do artigo em questão.

Sumarização dos resultados:

Um artigo apresentando os resultados será escrito. Ele irá conter tabelas, gráficos e outros diagramas que ilustram a avaliação das técnicas e ferramentas analisadas nos artigos.