

**U F *m* G**

UNIVERSIDADE FEDERAL  
DE MINAS GERAIS

**UNIVERSIDADE FEDERAL DE MINAS GERAIS**

**FACULDADE DE MEDICINA**

**PROGRAMA DE PÓS-GRADUAÇÃO EM INFECTOLOGIA E MEDICINA  
TROPICAL**

**WILTON BATISTA DE SANTANA JÚNIOR**

**USO DA INTELIGÊNCIA ARTIFICIAL APLICADA  
AO ELETROCARDIOGRAMA PARA DIAGNÓSTICO  
DE DISFUNÇÃO SISTÓLICA VENTRICULAR ESQUERDA**

Belo Horizonte  
2023

**WILTON BATISTA DE SANTANA JÚNIOR**

**USO DA INTELIGÊNCIA ARTIFICIAL APLICADA  
AO ELETROCARDIOGRAMA PARA DIAGNÓSTICO  
DE DISFUNÇÃO SISTÓLICA VENTRICULAR ESQUERDA**

Dissertação apresentada ao Programa de Pós-graduação em Infectologia e Medicina Tropical da Universidade Federal de Minas Gerais como requisito parcial para obtenção do título de Mestre em Infectologia e Medicina Tropical.

Orientador: Prof. Dr. Antônio Luiz Pinho Ribeiro

Co-orientador: Dr Marcelo Martins Pinto Filho

Belo Horizonte  
2023

SA232i Santana Júnior, Wilton Batista de.  
Uso da Inteligência Artificial (IA) aplicada ao Eletrocardiograma (ECG) para diagnóstico de Disfunção Sistólica Ventricular Esquerda (DSVE) [recursos eletrônicos]. / Wilton Batista de Santana Júnior. - - Belo Horizonte: 2023.

59f.: il.

Formato: PDF.

Requisitos do Sistema: Adobe Digital Editions.

Orientador (a): Antônio Luiz Pinho Ribeiro.

Coorientador (a): Marcelo Martins Pinto Filho.

Área de concentração: Infectologia e Medicina Tropical.

Dissertação (mestrado): Universidade Federal de Minas Gerais, Faculdade de Medicina.

1. Inteligência Artificial. 2. Insuficiência Cardíaca. 3. Disfunção Ventricular Esquerda. 4. Eletrocardiografia. 5. Dissertação Acadêmica. I. Ribeiro, Antônio Luiz Pinho. II. Pinto Filho, Marcelo Martins. III. Universidade Federal de Minas Gerais, Faculdade de Medicina. IV. Título.

NLM: W 26.55.A7



UNIVERSIDADE FEDERAL DE MINAS GERAIS  
FACULDADE DE MEDICINA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DA SAÚDE INFECTOLOGIA E MEDICINA TROPICAL  
**ATA DE DEFESA DE DISSERTAÇÃO**

Às **13:00** horas do dia 01 de novembro de 2023, no Canal do CETES - Plataforma LIFESIZE, realizou-se a sessão pública para a 440ª defesa de dissertação de **WILTON BATISTA DE SANTANA JÚNIOR**, número de registro 2020717683, graduado no curso de MEDICINA, como requisito parcial para a obtenção do grau de Mestre em CIÊNCIAS DA SAÚDE. A presidência da sessão coube ao professor **ANTONIO LUIZ PINHO RIBEIRO**, orientador. Inicialmente, o presidente fez a apresentação da Comissão Examinadora assim constituída: **PROF. ANTONIO LUIZ PINHO RIBEIRO - ORIENTADOR (UFMG)**, **PROF. MARCELO MARTINS PINTO FILHO – COORIENTADOR (HC-UFGM)**, **PROF. FÁBIO MORATO DE CASTILHO (UFMG)**, **PROF. MARCO PAULO TOMAZ BARBOSA (HC-UFGM)**. Em seguida, o candidato fez a apresentação do trabalho que constitui sua **Dissertação de Mestrado**, intitulada: **"USO DA INTELIGÊNCIA ARTIFICIAL (IA) APLICADA AO ELETROCARDIOGRAMA (ECG) PARA DIAGNÓSTICO DE DISFUNÇÃO SISTÓLICA VENTRICULAR ESQUERDA (DSVE)"**. Seguiu-se a arguição pelos examinadores e logo após, a Comissão reuniu-se, sem a presença do candidato e do público e decidiu considerar **APROVADO**. O resultado final foi comunicado publicamente ao candidato e ao público, pelo presidente da Comissão. Conforme arts. 76 e 77 das Normas Gerais de Pós-Graduação da UFGM, as defesas de dissertação e tese são públicas. O aluno e os membros da banca estão cientes e autorizaram a gravação desta defesa, que ficará disponibilizada em acervo da Universidade. Nada mais havendo a tratar, o presidente encerrou a sessão, sendo lavrada a presente ata que, depois de lida e aprovada, foi assinada pela Comissão Examinadora.

**Belo Horizonte, 01 de novembro de 2023.**

Assinatura dos membros da banca examinadora:



Documento assinado eletronicamente por **Marcelo Martins Pinto Filho, Usuário Externo**, em 01/11/2023, às 14:38, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Antonio Luiz Pinho Ribeiro, Coordenador(a)**, em 03/11/2023, às 10:18, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fabio Morato de Castilho, Professor do Magistério Superior**, em 06/11/2023, às 12:55, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Marco Paulo Tomaz Barbosa, Médico**, em 06/11/2023, às 21:30, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

## **UNIVERSIDADE FEDERAL DE MINAS GERAIS**

### **REITOR**

Profa Sandra Regina Goulart Almeida

### **VICE-REITORA**

Prof Alessandro Fernandes Moreira

### **PRÓ-REITOR DE PÓS-GRADUAÇÃO**

Bruno Otávio Soares Teixeira

### **PRÓ REITORA DE PESQUISA**

Fernando Marcos dos Reis

### **FACULDADE DE MEDICINA**

**DIRETOR:** Profa. Alamanda Kfoury Pereira

**VICE-DIRETOR:** Profa. Cristina Gonçalves Alvim

### **CENTRO DE PÓS-GRADUAÇÃO**

**COORDENADOR:** Prof. Tarcizo Afonso Nunes

**SUBCOORDENADORA:** Prof.<sup>a</sup> Eli Iola Gurgel Andrade

### **COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DA SAÚDE:**

#### **INFECTOLOGIA E MEDICINA TROPICAL**

Prof. Eduardo Antônio Ferraz Coelho (Coordenador)

Prof. Vandack Alencar Nobre Junior (Subcoordenador)

Prof. Daniel Vitor de Vasconcelos Santos

Profa. Denise Utsch Gonçalves

Prof. Eduardo Antônio Ferraz Coelho

Profa. Maria Auxiliadora Parreiras Martins

Profa. Mariana Costa Duarte

Prof. Walderez Ornelas Dutra

Raquel Soares Bandeira Câmara – Representante Discente

**WILTON BATISTA DE SANTANA JÚNIOR**

**USO DA INTELIGÊNCIA ARTIFICIAL APLICADA AO ELETROCARDIOGRAMA  
PARA DIAGNÓSTICO DE DISFUNÇÃO SISTÓLICA VENTRICULAR ESQUERDA**

Dissertação apresentada ao Programa de Pós-graduação em Infectologia e Medicina Tropical da Universidade Federal de Minas Gerais como requisito parcial para obtenção do título de Mestre em Infectologia e Medicina Tropical.

Banca examinadora:

---

Prof. Dr. Antônio Luiz Pinho Ribeiro UFMG - (Orientador)

---

Dr. Marcelo Martins Pinto Filho - UFMG - (Coorientador)

---

Prof. Dr. Fábio Morato Castilho- UFMG

---

Dr. Marco Paulo Tomaz Barbosa – HC-UFMG

---

Profa. Dr Gabriel Assis Lopes do Carmo - UFMG (Suplente)

Belo Horizonte, 01 de novembro de 2023.

Ao meus pais, Wilton Batista de Santana (*in memoriam*) e Ângela Maria Viana,  
que, com sua dedicação e paciência, possibilitaram que eu me tornasse quem eu sou hoje;  
Aos meus irmãos, Raul e Daniela, sempre presentes nos momentos difíceis;  
À minha amada, paciente e tão companheira esposa, Sarita,  
sempre com sua dedicação intransigente;  
Ao meu filho, Gabriel, fonte nova de alegria e motivação para continuar em movimento;  
Aos meus amigos Rodrigo, Tati, Lilian, Fernanda, Juliana, Beatriz,  
Leandro, Carlos Henrique, Everaldo e Adriana, pelos bons momentos  
necessários nesses mais de vinte e tantos anos de amizade.

## AGRADECIMENTOS

Ao Prof. Antônio Luiz Pinho Ribeiro (Tom), pela disposição em me orientar e pela tranquilidade e serenidade nas sugestões de análises do estudo.

Ao Marcelo Martins Pinto Filho, pela disponibilidade e empenho para discutir cada detalhe do trabalho.

Ambos me mostraram o caminho para se fazer boa ciência, ato de extremo valor nesses tempos de negacionismo científico.

Aos participantes, à equipe de pesquisadores e colaboradores do Estudo Longitudinal de Saúde do Adulto por seu papel relevante para o avanço da medicina no Brasil.

À equipe de Telessaúde do Hospital das Clínicas da UFMG, em especial a Leonardo Bonisson Ribeiro (Léo), agradeço pelo empréstimo do computador para análise estatística e pela disponibilidade em atender outras demandas.

À Gleiceane, secretária do Telessaúde, pela sua presteza em lidar com minhas solicitações, seja nas reuniões com o Professor Tom ou em outras questões.

À UFMG, onde iniciei minha vida acadêmica em 1999 na Engenharia Química, passando pela Farmácia e, finalmente, na Medicina; onde me especializei em cardiologia e atuo como servidor.

"Enquanto navegamos pelas ondas sinuosas do eletrocardiograma, a inteligência artificial serve como um farol, tanto revelando quanto moldando o desconhecido. No entanto, como Prometeu com seu fogo, devemos manusear esse farol com cuidado; pois, se nos perdermos em sua luz deslumbrante, corremos o risco de nos distanciar da própria essência da medicina - o toque humano compassivo."  
(*ChatGPT – 5/6/2023*)

## RESUMO

**INTRODUÇÃO:** a insuficiência cardíaca (IC) é uma das três causas mais comuns de doenças cardiovasculares (DCV), grupo de enfermidades que é a principal causa de morbimortalidade no mundo. O eletrocardiograma (ECG) é um dos exames utilizados na avaliação da IC, sendo de baixo custo e amplamente acessível. Quando associado à inteligência artificial, o ECG pode ser uma poderosa ferramenta para triagem de indivíduos com maior probabilidade de IC. O objetivo foi avaliar o desempenho de um algoritmo de IA, aplicado ao ECG, para detecção de DSVE e compará-lo ao das alterações maiores ao ECG (AME), de acordo com o código de Minnesota. **MÉTODOS:** estudo transversal retrospectivo de acurácia diagnóstica que utilizou a população do Estudo Longitudinal da Saúde do Adulto (ELSA-Brasil). Foram avaliados 2567 indivíduos que possuíam ecocardiograma (ECO) e ECG válidos e valores de predição para disfunção sistólica do ventrículo esquerdo (DSVE) estimadas por um algoritmo de inteligência artificial (IA). A DSVE foi definida como Fração de Ejeção do Ventrículo Esquerdo (FEVE) menor que 40%, calculada utilizando o ECO. A prevalência de DSVE foi de 1,13% na população estudada (29 indivíduos). Foram calculados sensibilidade, especificidade, valor preditivo positivo (VPP), valor preditivo negativo (VPN), razão de verossimilhança positivo (RVP), razão de verossimilhança negativa (RVN), diagnostic odds ratio (DOR) para o algoritmo e para as AME. Calculou-se também a área sob a curva ROC (ASC-ROC) para o algoritmo. **RESULTADOS:** a população estudada possui mediana de 62 anos, sendo 47,2% do sexo masculino. A ASC-ROC do algoritmo para predição de IC foi de 0,947 (IC 95% 0,913 – 0,981). A sensibilidade, especificidade, VPP, VPN, RVP, RVN e DOR para o algoritmo foi de 0,690; 0,976; 0,244; 0,996; 27,6; 0,32 e 88,74, respectivamente. Para as AME foi 0,172; 0,837; 0,012; 0,989; 1,09; 0,990 e 1,07 respectivamente. **CONCLUSÕES:** A IA aplicada ao ECG é uma ferramenta promissora para identificação de pacientes com maior probabilidade de IC e que devem ser priorizados para realização de ECO. Isso poderia aprimorar o diagnóstico de IC em nosso meio e, assim, permitir o início precoce do tratamento, com possível impacto na redução da morbidade e mortalidade.

**Palavras-chave:** inteligência artificial; insuficiência cardíaca; disfunção sistólica do ventrículo esquerdo; eletrocardiografia; ELSA-Brasil.

## ABSTRACT

**INTRODUCTION:** Heart failure (HF) is one of the three most common causes of cardiovascular diseases (CVD), which are the leading causes of morbidity and mortality worldwide. The electrocardiogram (ECG) is one of the tests used in the evaluation of HF, combining low-cost and wide accessibility. When combined with artificial intelligence, the ECG can be a powerful tool for screening individuals with a higher risk of HF. Our objective was to assess the performance of an AI algorithm applied to the ECG for the detection of left ventricular systolic dysfunction (LVSD) and compare it to the performance of major ECG abnormalities (MEA) according to the Minnesota code. **METHODS:** This was a retrospective cross-sectional diagnostic accuracy study using data from the Brazilian Longitudinal Study of Adult Health (ELSA-Brazil). A total of 2567 individuals with valid echocardiograms (ECO) and ECGs and probability values for left ventricular systolic dysfunction (LVSD) estimated by an artificial intelligence (AI) algorithm, were evaluated. LVSD was defined as a left ventricular ejection fraction (LVEF) less than 40%, calculated using ECO. The prevalence of LVSD was 1.13% in the studied population (29 individuals). Sensitivity, specificity, positive predictive value (PPV), negative predictive value (NPV), positive likelihood ratio (PLR), negative likelihood ratio (NLR), and diagnostic odds ratio (DOR) were calculated for the algorithm and MEA. The area under the ROC curve (AUC-ROC) was also calculated for the algorithm. **RESULTS:** The study population had a median age of 62 years, with 47.2% being male. The AUC-ROC for the algorithm to predict HF was 0.947 (95% CI 0.913 – 0.981). Sensitivity, specificity, PPV, NPV, PLR, NLR, and DOR for the algorithm were 0.690, 0.976, 0.244, 0.996, 27.6, 0.32, and 88.74, respectively. For MEA, it was 0.172, 0.837, 0.012, 0.989, 1.09, 0.990, and 1.07, respectively. **CONCLUSIONS:** AI applied to the ECG is a promising tool for identifying patients with a higher likelihood of HF who should be prioritized for ECO. This could improve the diagnosis capacity of HF in our setting and thus enable early treatment initiation, with possible impact on reducing morbidity and mortality.

**Keywords:** artificial intelligence; heart failure; left ventricular systolic dysfunction; electrocardiography; ELSA-Brazil.

## LISTA DE FIGURAS

<b>Figura 1</b> – Carga de doença, expressa em Disability adjusted life years, Global e no Brasil. 15	
<b>Figura 2</b> – Domínios da Inteligência Artificial.....	23
<b>Figura 3</b> – Modelo de rede neural artificial (RNA) (18) .....	24
<b>Figura 4</b> – Modelo de neurônio artificial (18).....	25
<b>Figura 5</b> – <i>Gradient-weighted class activation mapping</i> destacando as derivações V2 e V3.	30

## ARTIGO

<b>Figura 1</b> – Fluxograma de seleção dos participantes .....	45
<b>Figura 2</b> – Área sob a curva ROC do algoritmo de RNC para predição maior que 10% de FEVE < 40%.....	45

## LISTA DE TABELAS

<b>Tabela 1</b> – Achados de acurácia dos estudos que avaliaram o uso de IA aplicado ao ECG para detecção de DSVE.....	30
--	----

## ARTIGO

<b>Tabela 1</b> – Características clínicas dos participantes do estudo.....	43
<b>Tabela 2</b> – Alterações eletrocardiográficas maiores e suas frequências, de acordo com o código de Minnesota .....	43
<b>Tabela 3</b> – Distribuição dos valores de predição do algoritmo de IA de acordo com a FEVE. ....	44
<b>Tabela 4</b> – Distribuição das alterações maiores ao ECG de acordo com a FEVE .....	44
<b>Tabela 5</b> - Sensibilidade, especificidade, VPP, VPN, RVP, RVN, DOR para o algoritmo de RNC e para as alterações maiores ao ECG. ASC-ROC para o algoritmo de RNC.....	44
<b>Tabela Suplementar:</b> Características clínicas dos participantes do ELSA-Brasil versus participantes do estudo.....	46

## LISTA DE ABREVIATURAS E SIGLAS

AHA	American Heart Association
AM	Aprendizado de Máquina
AME	Alterações Maiores ao Eletrocardiograma
ASC-ROC	Área sob a Curva ROC (Receiver Operator Characteristic Curve)
AVC	Acidente Vascular Cerebral
BRD	Bloqueio de Ramo Direito
BDAS	Bloqueio Divisional Ântero-Superior
AI-CDSS	Clinical Decision Support System
CHATGPT	Chat Generative Pre-Trained Transformer
DAC	Doença Arterial Coronariana
DALYs	Disability adjusted life years / Anos de vida perdidos ajustados por incapacidade
DCV	Doença Cardiovascular
DIC	Doença Isquêmica do Coração
DM	Diabetes Melito
DSVE	Disfunção Sistólica Ventricular Esquerda
ECG	Eletrocardiograma
ECO	Ecocardiograma
ELSA	Estudo Longitudinal da Saúde do Adulto
FA	Fibrilação Atrial
FEVE	Fração de Ejeção do Ventrículo Esquerdo
GBD	Global Burden Diseases
HAS	Hipertensão Arterial Sistêmica
IA	Inteligência Artificial
ICFEi	Insuficiência Cardíaca com Fração de Ejeção Intermediária
ICFEp	Insuficiência Cardíaca com Fração de Ejeção Preservada
ICFEr	Insuficiência Cardíaca com Fração de Ejeção reduzida
ICFErec	Insuficiência Cardíaca com Fração de Ejeção Recuperada
OMS	Organização Mundial de Saúde
OR	Odds Ratio
RNA	Rede Neural Artificial
SCA	Síndrome Coronariana Aguda
SGLT2	Cotransportador de Sódio-Glicose 2 (Sodium Glucose Linked Transporter 2)

SLG	Strain Longitudinal
SPECT	Tomografia Computadorizada por Emissão de Fóton Único (Single Photon Emission Computed Tomography)
SUS	Sistema Único de Saúde
VPN	Valor Preditivo Negativo
VPP	Valor Preditivo Positivo
UFMG	Universidade Federal de Minas Gerais

## SUMÁRIO

<b>1</b>	<b>CONSIDERAÇÕES INICIAIS</b> .....	<b>14</b>
<b>2</b>	<b>INTRODUÇÃO</b> .....	<b>15</b>
<b>3</b>	<b>REVISÃO DE LITERATURA</b> .....	<b>17</b>
3.1	CLASSIFICAÇÃO DA IC.....	17
3.2	DIAGNOSTICO E EXAMES COMPLEMENTARES.....	17
<b>3.2.1</b>	<b>Radiografia de tórax</b> .....	<b>18</b>
<b>3.2.2</b>	<b>ECG</b> .....	<b>18</b>
<b>3.2.3</b>	<b>Ecocardiograma transtorácico</b> .....	<b>19</b>
3.3	INTELIGÊNCIA ARTIFICIAL (IA).....	20
<b>3.3.1</b>	<b>Inteligência e inteligência artificial</b> .....	<b>20</b>
<b>3.3.2</b>	<b>Breve história da IA</b> .....	<b>21</b>
<b>3.3.3</b>	<b>Áreas da IA</b> .....	<b>22</b>
<b>3.3.4</b>	<b>Aplicações da IA</b> .....	<b>25</b>
<b>3.3.5</b>	<b>Inteligência artificial na medicina e na cardiologia</b> .....	<b>25</b>
<b>3.3.6</b>	<b>Aplicação da IA na IC</b> .....	<b>27</b>
<b>4</b>	<b>OBJETIVOS</b> .....	<b>32</b>
4.1	OBJETIVO GERAL .....	<b>Erro! Indicador não definido.</b>
4.2	OBJETIVOS ESPECÍFICOS.....	<b>Erro! Indicador não definido.</b>
<b>5</b>	<b>MATERIAIS E MÉTODOS</b> .....	<b>33</b>
5.1	PARTICIPANTES .....	33
5.2	PESQUISA BIBLIOGRÁFICA.....	<b>Erro! Indicador não definido.</b>
5.3	DEFINIÇÃO DAS VARIÁVEIS E TESTES DO ESTUDO .....	33
<b>5.3.1</b>	<b>Desenvolvimento da Rede Neural Convolutacional</b> .....	<b>33</b>
<b>5.3.2</b>	<b>Obtenção do eletrocardiograma</b> .....	<b>34</b>
<b>5.3.3</b>	<b>Obtenção do ecocardiograma</b> .....	<b>34</b>
5.4	ANÁLISE ESTATÍSTICA .....	35
5.5	CONSIDERAÇÕES ÉTICAS.....	35
<b>6</b>	<b>RESULTADO E DISCUSSÃO (ARTIGO)</b> .....	<b>36</b>
<b>7</b>	<b>CONSIDERAÇÕES FINAIS</b> .....	<b>49</b>
<b>8</b>	<b>PERSPECTIVAS</b> .....	<b>50</b>
	<b>REFERÊNCIAS</b> .....	<b>51</b>

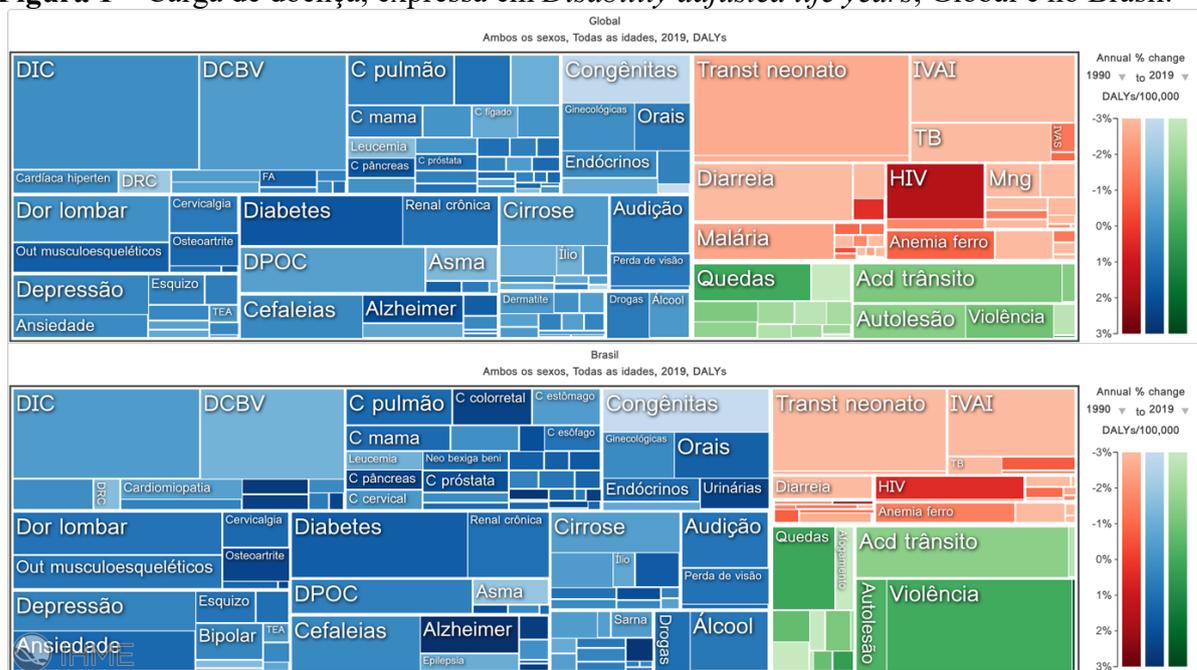
## 1 CONSIDERAÇÕES INICIAIS

O presente estudo foi desenvolvido utilizando o banco de dados do Estudo Longitudinal da Saúde do Adulto (ELSA – Brasil) que atualmente está na 4 onda. Trata-se de um estudo iniciado em 2008 que tem acompanhado 15105 indivíduos de centros universitários e institutos de pesquisa com propósito de compreender melhor a saúde do brasileiro no que tange a principalmente a doenças cardiovasculares e diabetes. Esse estudo é fruto de uma parceria entre o *Yale New Haven Hospital* e o Centro de Telessaúde do Hospital das Clínicas da UFMG na área de Inteligência Artificial (IA). Avaliou-se o desempenho de um algoritmo de IA aplicado ao eletrocardiograma (ECG) para detecção de indivíduos com disfunção sistólica do ventrículo esquerdo (DSVE). Esse desempenho foi comparado ao das Alterações Maiores ao ECG (AME). Tal ferramenta poderá ser muito útil na triagem de indivíduos com suspeita de insuficiência cardíaca com fração de ejeção reduzida (ICFEr) e que deverão ser priorizados para realização de ecocardiograma (ECO) diagnóstico.

## 2 INTRODUÇÃO

As doenças cardiovasculares (DCV) foram responsáveis por 1/3 das mortes no mundo em 2019, de acordo com as estimativas do estudo *Global Burden Diseases* (GBD), sendo a principal causa de DALYs (Anos de vida perdidos ajustados por incapacidade – do inglês, *Disability Adjusted Life-Year*) (1). Essa tendência também é observada no Brasil que possui prevalência de DCV estimada em 6,1% da população adulta e incidência de 475 casos/100.000 habitantes (Figura 1). Entre 1990 e 2019 houve crescimento contínuo da prevalência de DCV no Brasil. Entretanto, houve redução desse indicador quando ajustado por idade e considerando o mesmo período (2).

**Figura 1** – Carga de doença, expressa em *Disability adjusted life years*, Global e no Brasil.



Fonte: Global Burden Diseases (1). Observações: Em tons de azul, doenças não-transmissíveis; em tons de vermelho doenças transmissíveis, maternas, neonatais e nutricionais; em tons de verde, causas externas. Quanto maior a área do retângulo, maior o Disability adjusted life years. Legenda: DIC – doença isquêmica cardíaca; DCBV – doença cérebro-vascular; e DPOC – doença pulmonar obstrutiva crônica.

A insuficiência cardíaca (IC) é uma das três principais causas de DCV, juntamente com a doença isquêmica do coração (DIC) e o acidente vascular cerebral (AVC) (2). Os fatores de risco para o desenvolvimento de IC incluem a doença arterial coronariana (DAC), miocardite, doença valvar, cardiopatias congênitas, hipertensão arterial sistêmica (HAS), diabetes melito (DM) e obesidade (3–6). Vale lembrar que no Brasil, doenças negligenciadas, como a cardiopatia chagásica e a reumática, figuram como causas frequentes de IC (5).

Trata-se de uma síndrome complexa resultante de danos estruturais e/ou funcionais ao coração que geram comprometimento do enchimento ventricular e/ou redução do débito

cardíaco, ou seja, dos componentes diastólico e sistólico, respectivamente. Apresenta-se com sintomas e sinais como dispneia, fadiga e edema de membros inferiores, crepitações pulmonares, tosse, perda de peso (3,4,6).

É uma doença grave que afeta cerca de 64 milhões de pessoas no mundo (7). Alguns fatores explicam a prevalência de IC: (a) os avanços no tratamento de doenças que resultam em IC, como infarto, doenças valvares, arritmias, cardiopatias congênitas (4); (b) a melhora considerável dos meios diagnósticos (3); (c) aumento da expectativa de vida e (4) aumento na incidência de fatores de risco relacionado à IC (8).

Nos últimos 30 anos houve avanços expressivos em relação ao tratamento farmacológico da IC, como o uso de betabloqueadores, antagonistas mineralocorticóides, inibidores do sistema renina-angiotensina e, mais recentemente, com a introdução do inibidor de neprililina e dos inibidores do SGLT2 (4,5). Esses avanços impactaram na mortalidade da IC, que, entretanto, continua alta, com sobrevida média em 5 e 10 anos de 50% e 10%, respectivamente (8).

Nos EUA, estima-se que a IC afete 6,2 milhões de pessoas com aumento exponencial da prevalência na população acima de 65 anos (4). Na Europa, a prevalência situa-se entre 1-2% da população adulta, sendo maior que 10% na população maior de 70 anos, e com incidência de 5/1000 pessoas-ano nos adultos (6). Nessas duas regiões o risco de desenvolver IC em pessoas de 40 anos é da ordem de 20% (4).

Na América Latina, de acordo com dados da Organização Mundial de Saúde (OMS), houve aumento na incidência de fatores de risco relacionado à IC, sobretudo devido ao aumento na expectativa de vida, inatividade física, aumento de ingestão de dietas ricas em gorduras e hipercalóricas e urbanização das populações (8). Além disso, trata-se de uma região com histórico de baixo investimentos em saúde e acesso precário aos serviços de saúde, aumentando sobremaneira a morbidade por IC (5).

No Brasil estima-se que a prevalência de IC seja de 2 milhões de indivíduos com uma incidência anual de 240.000 casos (9). Quando se avalia a prevalência padronizada por idade, observa-se redução entre 1990 e 2017. No entanto, a carga de doença subiu nesse mesmo período, passando de 88.114 para 234.169 DALYs. Entre 2008 e 2019 houve mais de 3 milhões de hospitalizações por IC, segundo dados do Sistema Único de Saúde (SUS), com um custo não ajustado por volta de R\$ 4 bilhões (2). Somente em 2019 houve mais de 222 mil internações por IC no Brasil a um custo de quase de R\$ 360 milhões (2). Em média, após o diagnóstico de IC, os indivíduos demandam internação uma vez ao ano. Além disso, temos uma das maiores taxas de mortalidade intra-hospitalar por IC no mundo ocidental (5,10).

### 3 REVISÃO DE LITERATURA

#### 3.1 CLASSIFICAÇÃO DA IC

A IC pode ser classificada quanto à gravidade dos sintomas (classificação funcional), quanto à fração de ejeção do ventrículo esquerdo (FEVE) e de acordo com o estágio da doença.

A Classificação Funcional é realizada de acordo com a *New York Heart Association* (NYHA) e leva em conta a tolerância ao esforço físico, variando de Classe I, com sintomas aos grandes esforços, até Classe IV, com sintomas em repouso. Esta classificação é útil para o acompanhamento ambulatorial dos indivíduos, principalmente em relação ao ajuste do tratamento farmacológico.

Quanto à FEVE, os indivíduos podem ser classificados como tendo IC com FEVE normal ( $\geq 50\%$ ), também chamada de IC com FEVE preservada (ICFEp), IC com FEVE reduzida ( $<40\%$ ) (ICFEr) e IC com fração de ejeção levemente reduzida ou intermediária (ICFEi), quando a FEVE está entre 40 e 49%. Há a IC com FEVE recuperada (ICFErec) que caracterizada pela melhora da FEVE após tratamento (5,6). Estima-se que metade dos pacientes com IC possuam ICFEr e metade, ICFEp ou ICFEi, sendo que aqueles com FEVE preservada possuem, em geral, melhor prognóstico (6).

Por fim, de acordo com a *American Heart Association* (AHA), a IC pode ser classificada em 4 estágios, A, B, C e D. No A, o indivíduo apenas possui fatores de risco para desenvolver IC, ou seja, não há sintomas, nem doença estrutural. No B, há alteração estrutural, porém o indivíduo nunca teve sintomas. No C, há doença estrutural e sintomas atuais ou prévios. Por fim, no D os sintomas são refratários, havendo necessidade de intervenções especializadas, como transplante cardíaco (11).

#### 3.2 DIAGNOSTICO E EXAMES COMPLEMENTARES

Para o diagnóstico de IC é imprescindível história clínica e exame físico detalhados. O ECO é fundamental para a classificação quanto à FEVE, além de fornecer outras informações importantes sobre a anatomia cardíaca, auxiliando no diagnóstico etiológico, conduta e prognóstico. O ECO, aliado ao ECG e radiografia de tórax (Rx), são os exames complementares mais utilizados no diagnóstico de IC (4,5).

### 3.2.1 Radiografia de tórax

Apesar do avanço dos meios diagnósticos, o Rx permanece como um exame extremamente útil na avaliação de indivíduos sob suspeita de IC e naqueles que apresentam descompensação do quadro clínico. Por meio dele é possível identificar cardiomegalia, congestão pulmonar, cefalização de fluxo. Além disso, é útil na investigação de outras causas de dispneia. Possui baixa sensibilidade (~68%) e é mais útil em quadros agudos, nos quais os mecanismos que produzem congestão pulmonar estão mais evidentes (3–6).

### 3.2.2 ECG

O ECG é amplamente utilizado nos distúrbios do ritmo cardíaco e na isquemia miocárdica. Também faz parte da avaliação inicial de indivíduos com suspeita de IC.

Algumas alterações presentes ao ECG podem sugerir etiologias como isquemia miocárdica na presença de onda Q patológica e na ausência de progressão da onda R nas derivações precordiais, ou doença de Chagas na presença de bloqueio do ramo direito (BRD) e bloqueio divisional ântero-superior (BDAS). Dentre os achados ao ECG, as AME (Tabela 2) são indicativas de cardiopatia estrutural, demandando extensão propedêutica e possuindo valor prognóstico, como o bloqueio de ramo esquerdo (BRE) (4–6,8).

Há poucos estudos avaliando o valor preditivo das AME para DSVE. Um dos primeiros foi publicado em 1996 por Davie *et al.* e avaliou o valor da fibrilação atrial, infarto do miocárdio, sobrecarga ventricular esquerda, bloqueio de ramo esquerdo ou desvio à esquerda do eixo cardíaco para diagnóstico de DSVE. Os valores de sensibilidade, especificidade, valor preditivo positivo (VPP) e valor preditivo negativo (VPN) foram 0,94; 0,61, 0,35 e 0,98, respectivamente. Nesse estudo a prevalência de DSVE foi 16,85% (12).

Moster *et al.* avaliaram o acurácia do ECG no diagnóstico de DSVE. Os traçados alterados tinham as mesmas alterações do estudo de Davie *et al.*, além de flutter atrial. A prevalência de DSVE nesse estudo foi 3%. Foram realizadas análises para a população geral e para um grupo definido como de alta probabilidade pré-teste para DSVE, pois era constituído de indivíduos com achados de alto risco como dispneia aos esforços e IAM prévio. Para a população geral a sensibilidade, especificidade, valor preditivo positivo (VPP) e valor preditivo negativo (VPN) foram 0,54; 0,79; 0,07 e 0,98, respectivamente. Para o grupo de alta probabilidade pré-teste os valores foram 0,64; 0,73; 0,10 e 0,98, respectivamente (13).

Goudie *et al.* também avaliaram o valor dessas alterações, relatadas por clínicos gerais, para predição de DSVE em uma população na qual a prevalência de IC foi 27,3%. Os valores encontrados de sensibilidade, especificidade, VPP e VPN foram, respectivamente, 0,94; 0,58; 0,47 e 0,96 (14).

Em uma revisão sistemática, Madhok *et al.*, avaliaram o valor das alterações ao ECG (sobrecarga ventricular esquerda – SVE -, infarto prévio, bloqueio de ramo) para o diagnóstico de DSVE, e encontraram uma razão de verossimilhança negativa (RVN) variando entre 0,06 e 0,76 (15).

Mant *et al.*, em uma metanálise, avaliaram a sensibilidade, especificidade, *diagnostic odds ratio* (DOR), razão de verossimilhança positivo (RVP) e razão de verossimilhança negativo (RVN) das alterações do ECG (onda Q patológica, bloqueio de ramo completo ou incompleto, SVE, fibrilação atrial, alterações do segmento ST e/ou da onda T, taquicardia sinusal) para diagnóstico de IC, obtendo valores de 0,89; 0,56; 4,80; 2,03 e 0,19, respectivamente (16).

### 3.2.3 Ecocardiograma transtorácico

O ECO é o exame de eleição para diagnóstico de indivíduos com suspeita de IC. Trata-se de um método seguro, não envolvendo radiação, podendo ser realizado beira-leito. Permite a avaliação da função e estrutura do miocárdio, valvas e pericárdio, bem como das pressões e fluxos intracardíacos, além de estimar o valor da FEVE, fundamental para classificação da IC. Alguns achados podem sugerir etiologias específicas da IC como hipertensão arterial sistêmica quando se observa hipertrofia concêntrica ou DAC, quando há déficits segmentares. Mais recentemente, o uso do Strain Logitudinal Global (SLG) tem sido utilizado em pacientes submetidos à quimioterapia como parâmetro capaz de estimar o risco de desenvolver IC. Por essas características, é um exame muito importante no planejamento terapêutico e na estratificação prognóstica (3,5,6,8).

No entanto, possui limitações de ordem técnica e de logística. Quanto à primeira, a janela acústica inadequada é a principal, sobretudo em pessoas com deformidades da caixa torácica, obesos e com hiperinsuflação pulmonar (8). Do ponto de vista logístico, é um exame que requer aparelho de ultrassonografia, restringindo sua difusão no nosso país devido aos custos financeiros para aquisição e manutenção do dispositivo. Além disso, demanda médico com formação em cardiologia e especialização em ecodopplercardiografia para sua realização. Tudo isso somado, dificulta sua ampla utilização na avaliação de pacientes com IC ou suspeitos.

### 3.3 INTELIGÊNCIA ARTIFICIAL (IA)

#### 3.3.1 Inteligência e inteligência artificial

Não há consenso na comunidade científica sobre o que é inteligência, havendo várias definições, não excludentes entre si, o que mostra a dificuldade em defini-la. Os processos mentais que propiciam um comportamento inteligente não são ainda completamente compreendidos, apesar dos avanços tecnológicos recentes. De acordo com Minsky, “inteligência é o nome que damos a qualquer um destes processos que ainda não compreendemos” (17). Dito de outra forma, inteligência é algo fácil de perceber, porém difícil de definir. Minsky criticava “o ato de forçar definições para coisas que ainda não entendemos”, como a inteligência, argumentando que isso pode ser contraproducente (18).

Entretanto, alguns elementos são comuns nas definições propostas como aprender com a experiência, dependência da interação com o ambiente, resolução de problemas e desenvolvimento de estruturas cognitivas (19).

Em 1950, Alan Turing propôs um teste que leva seu nome e que poderia ser utilizado para identificar agentes inteligentes. Para um computador passar no teste, um humano não deveria ser capaz de diferenciar se as respostas a determinadas perguntas viriam de um computador ou de outro humano (20). Hoje já existem ferramentas que passam no teste de Turing, como o ChatGPT (*Chat Generative Pre-Trained Transformer*) (21), que utiliza o processamento de linguagem natural. Contudo, seria precipitado dizer que a inteligência humana funciona como o ChatGPT. Talvez o mais correto seja dizer que ela emula suficientemente bem uma das características da inteligência humana a ponto de não sermos capazes de diferenciar suas respostas das de um ser humano.

O termo IA foi proposto por John McCarthy em 1956, um dos idealizadores desse conceito, que o definiu como “fazer a máquina comportar-se de tal forma que seja chamada inteligente caso fosse este o comportamento de um ser humano” (22). Fernandes conceitua a IA como parte da ciência da computação voltada para o desenvolvimento de sistemas inteligentes (23). Lima fala da constituição da IA em “vários procedimentos computacionais cujas funções realizadas, caso um ser humano as executasse seriam consideradas inteligentes” (18). Tanto Fernandes quanto Lima incluem o termo ‘inteligência’ na definição tornando-as definições circulares.

Para Dijkstra o questionamento se uma máquina é inteligente ou pode pensar equivale a perguntar se um submarino pode nadar; o que importa é se o objetivo final foi atingido por

uma máquina. Se tal objetivo for alcançado, ela pode ser considerada inteligente (23). Esse posicionamento lembra o de Minsky, um dos fundadores da IA, que criticava a busca forçosa por uma definição de inteligência que é algo que ainda não entendemos (18).

Russel e Norvig, propõem 8 definições de IA que podem ser divididas em 4 grupos: pensar como humanos, agir como humanos, pensar racionalmente e agir racionalmente. Temos então 2 dimensões: a do pensar e agir e humano e racional. Agir como humano implica uma série de competências: processamento da linguagem natural, representação do conhecimento, raciocínio automatizado, aprendizado de máquina (AM) ou *machine learning*, visão computacional e robótica, sendo estes os principais campos de estudo da IA (Figura 2) (20). Isso denota o enfoque no resultado, como explicitado no pensamento de Dijkstra e, de certa forma, de Minsky.

Por fim, Luger propõe que IA é “o ramo da ciência da computação que se ocupa da automação do comportamento inteligente (24)” e uma de suas características diz respeito ao reconhecimento de padrões que é o pano de fundo do presente estudo.

### 3.3.2 Breve história da IA

A IA tem se tornando possível porque tem se beneficiado do desenvolvimento de várias áreas humanas com a filosofia, matemática, economia, neurociência, psicologia, engenharia de computadores, teoria do controle e cibernética, linguística (20).

Os primeiros estudos que possibilitaram o surgimento da IA surgiram durante a 2ª Guerra Mundial devido às demandas no desenvolvimento de sistemas que fossem, por exemplo, capazes de decifrar códigos. O nome computador vem da necessidade de realizar cálculos (cômputos) em grande escala. Os primeiros computadores surgiram em 1943, na Inglaterra (Colossus), e em 1946, nos EUA (Eniac). Após a 2ª Guerra, o uso de computadores se estendeu às universidades, indústrias e ao meio militar acelerando o desenvolvimento dessa área (18).

O primeiro trabalho a tratar da IA foi realizado por Walter Pitts e Warren McCulloch, em 1943, no qual propuseram um modelo de neurônio artificial que assumiria dois estados, ligado ou desligado (18,20).

Em 1950 Alan Turing propôs um teste que discutia a possibilidade de uma máquina poder emular o comportamento humano e uma maneira de descobrir isso (18,23). Hoje, como vimos, já existem sistemas capazes de passar nesse teste por emular certas características da inteligência humana, como o ChatGPT, que trabalha com processamento da linguagem natural.

Como mencionado, o termo IA foi cunhado em 1956 durante uma Conferência de verão promovida pelo Dartmouth College (Hanouver, New Hampshire) em 1956, conhecida como Conferência de Dartmouth. Essa conferência teve importância fundamental pois ajudou a estruturar o campo de pesquisa em IA a partir de discussões de temas como automação, uso computacional da linguagem natural, redes neurais, aleatoriedade (18,19,22,23).

Inicialmente, houve muito sucesso com o uso de computadores para desempenhar tarefas que, até então, eram tidas como exclusivas da inteligência humana. No entanto, boa parte do otimismo inicial foi se apacando à medida que problemas mais complexos não conseguiam ser resolvidos pelos sistemas desenvolvidos, em boa parte, devido ao baixo poder computacional das máquinas.

Sobreveio então o “inverno da IA”, nas décadas de 70 e 80, quando poucos progressos foram feitos nessa área. Em 1981, o Japão anunciou um plano ambicioso de desenvolver computadores inteligentes no prazo de 10 anos, utilizando a linguagem Prolog. Isso serviu de estímulo para que Europa e EUA investissem ou retomassem programas de pesquisa nessa área com investimentos que passaram da casa de milhões para bilhões de dólares (18,20,23).

Nas últimas décadas temos visto um formidável desenvolvimento da IA, possível graças ao aumento sem precedentes do poder computacional e de enormes volumes de dados disponibilizados na *World Wide Web*, fenômeno conhecido com *BIG DATA*.

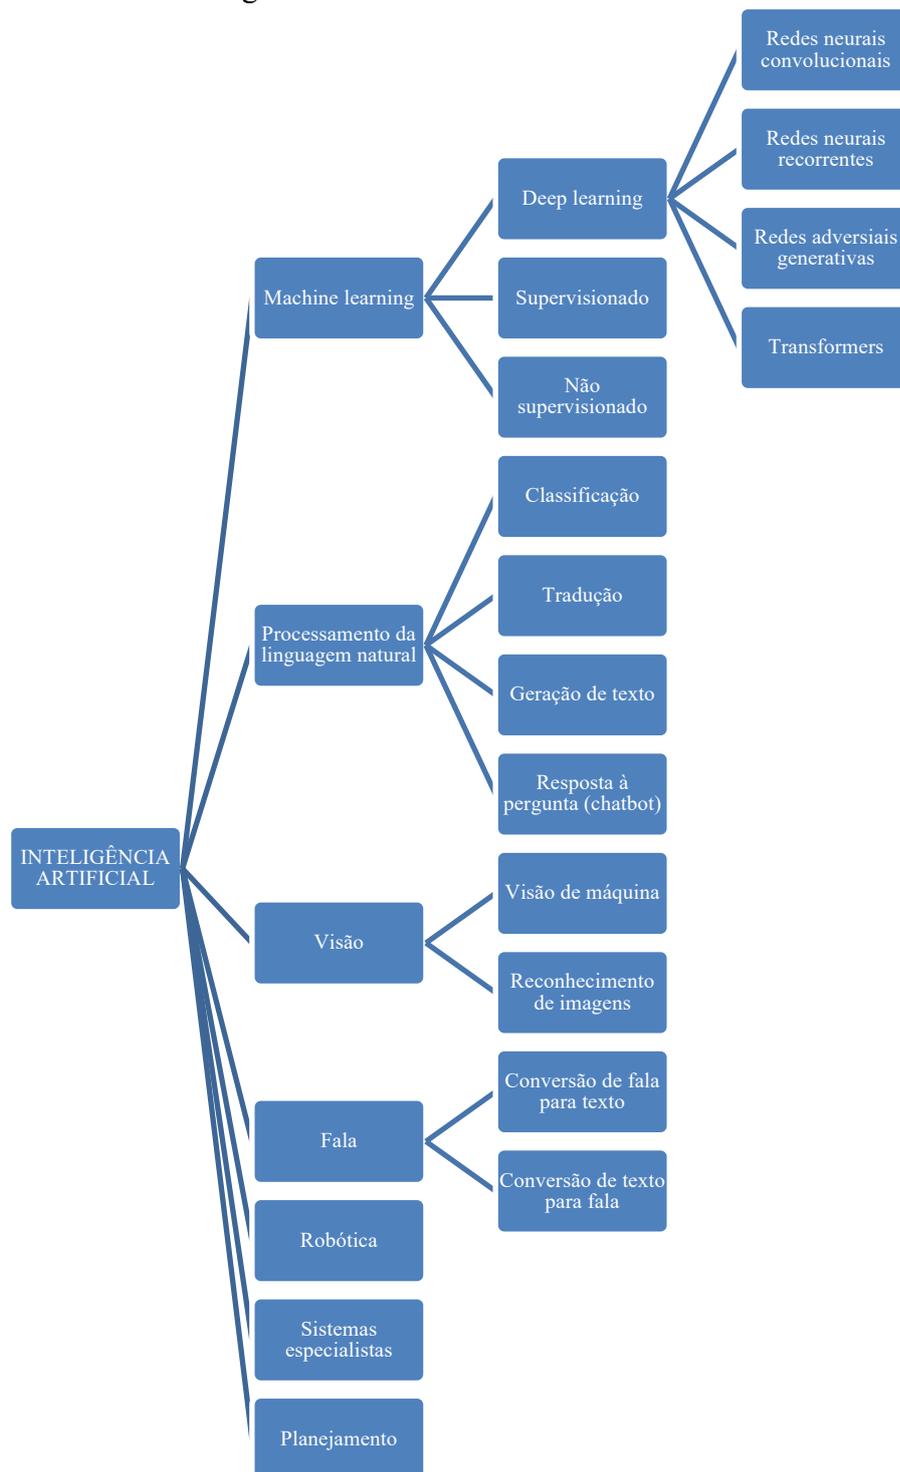
Uma das subáreas da IA é o AM que faz uso de redes neurais. Em 1970 já havia relatos do uso dessas redes e em 1990 houve sucesso no uso delas no reconhecimento de dígitos manuscritos. Porém, foi apenas a partir de 2011 que os métodos de aprendizado profundo ou deep learning (DL) tiveram desenvolvimento significativo, ampliando dramaticamente suas aplicações (18,20).

O AM tem como objetivo desenvolver sistemas que sejam capazes de adquirir conhecimento de forma automática e que os algoritmos de aprendizagem possam maximizar a capacidade de generalização, ou seja, sua capacidade de predição (18). Um dos campos do AM é o DL que trabalha com múltiplas camadas de redes neurais, em especial as redes neurais convolucionais (RNC) que foram utilizadas nesse trabalho. Tais redes têm se mostrado muito útil na avaliação de dados não estruturados como reconhecimento de voz e imagem.

### 3.3.3 Áreas da IA

A IA é um vasto campo de pesquisa com várias subáreas e métodos utilizados. Os seus principais domínios estão ilustrados na figura a seguir.

**Figura 2 – Domínios da Inteligência Artificial**

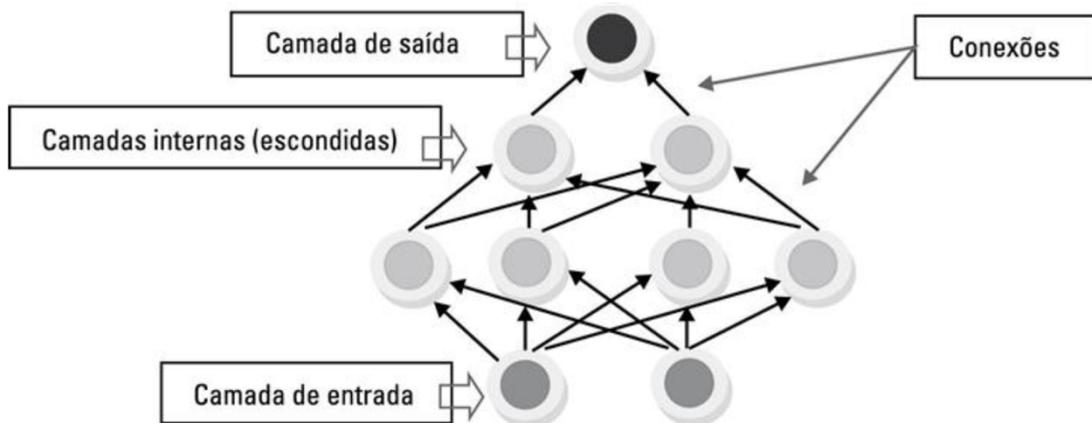


Fonte: Adaptado de Neves (25).

Para realização do presente trabalho foi utilizado um algoritmo de rede neural artificial (RNA) convolucional ou Rede Neural Convolucional (RNC) supervisionada. Um algoritmo é um conjunto de instruções passo a passo para realização de uma determinada tarefa. Em ciência da computação é uma sequência de etapas que transformam entrada em saída (26,27).

Uma RNA de DL emula o funcionamento de uma rede neural biológica e tem como pressuposto básico o aprendizado de padrões. Ela possui uma camada de entrada, uma camada de saída e, entre elas, várias camadas ocultas (Figura 3). Todas essas camadas são constituídas de neurônios artificiais (Figura 4), que formam conexões entre si. As RNA são dinâmicas, utilizam a “experiência” para modificar as respostas da rede de acordo com a situação. São também autoajustáveis, pois podem mudar constantemente para se adaptar a uma nova condição. Existem 3 fases no processo de criação de uma rede neural: aprendizado, treinamento e generalização. Na fase de aprendizado a rede é exposta a vários exemplos, criando associações e padrões. Na de treinamento, acontece o ajuste ou calibração, por meio da minimização de erros e iteração entre os vários elementos da rede. Finalmente, durante a generalização, a rede é exposta a novos dados e fazendo previsões sobre esses dados de acordo com o que foi aprendido nas etapas anteriores. Na RNC supervisionada, nas duas primeiras fases são apresentados os dados e suas respectivas saídas para que a rede efetue o aprendizado e treinamento (18).

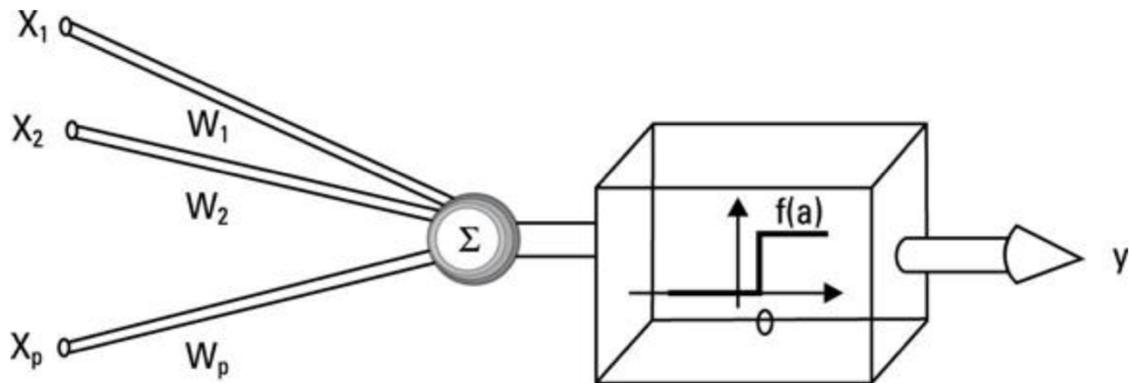
**Figura 3** – Modelo de rede neural artificial (RNA)



Fonte: Mant *et al.* (18).

Os dados (inputs) são inseridos na camada de entrada e processados nas múltiplas camadas internas, gerando uma informação (outputs) apresentada na camada de saída. As camadas são constituídas de neurônios artificiais; as conexões seriam as “sinapses” entre os neurônios.

**Figura 4** – Modelo de neurônio artificial



Fonte: Mant *et al.* (18).

Cada informação ( $X$ ) é multiplicada por um peso ( $W$ ) sendo somadas em um nó ( $\Sigma$ ). Se a informação resultante for maior que um limiar definido por uma função de ativação ( $f(a)$ ), uma resposta é gerada ( $y$ ). Analogamente a um neurônio biológico,  $X$  seria o estímulo,  $W$ , o dendrito,  $\Sigma$ , o corpo celular,  $f(a)$ , as diversas sinalizações intracelulares, e  $y$  a resposta ou disparo do neurônio.

### 3.3.4 Aplicações da IA

As aplicações da IA estão em constante evolução e a cada semana surgem novas possibilidades. Atualmente a aplicação da IA se dá na área de jogos, prova de teoremas matemáticos, processamento da linguagem natural, biometria, robótico, controle autônomo (18,20,23,24). Luger, no seu livro “Inteligência Artificial” de 2013, cita a área de Sistemas especialistas utilizada também no diagnóstico médico e cita algumas deficiências desses sistemas (24). No entanto, muitas dessas deficiências já foram superadas e, provavelmente, outras também serão, colocando as possíveis aplicações sempre em expansão.

Na área médica a IA se iguala ou supera os médicos especialistas, especialmente em condições cujo diagnóstico depende da interpretação de imagens. Isso ocorre na doença de Alzheimer, câncer de mama metastático, doenças oftalmológicas e de pele (28,29).

### 3.3.5 Inteligência artificial na medicina e na cardiologia

Como mencionado, a IA teve um período de grande expectativa seguido de um período denominado “inverno da IA”. E isso se refletiu também na área médica. Em 1959, Keeve Brodman afirmou que sendo o diagnóstico um processo lógico, ele poderia ser realizado por uma máquina. William B, Schwartz, em 1970, acreditava que até o ano 2000 haveria uma ampla substituição do médico pela IA. Felizmente, tais previsões não se confirmaram e em 1987 o mesmo Schwartz se questionava por que a revolução esperada não ocorrera. As abordagens

utilizadas para fins diagnósticos, sistema baseado em regras e reconhecimento de padrões, não tinham sido bem-sucedidas (30).

No entanto, dois fatores, ou revoluções, possibilitaram uma mudança de paradigma no uso da IA em medicina: o aumento sem precedentes da quantidade e das fontes de dados e o desenvolvimento da área de algoritmos, permitindo encontrar relações desconhecidas entre dados e, assim, extrair informações úteis que tivessem aplicação prática (30).

Na década de 1990 e início dos anos 2000 houve automação de algumas atividades como leitura de ECG, contagem diferencial de leucócitos, análise de fotografia da retina. Porém, tais atividades não são isentas de erros e ainda demandam supervisão humana (30). O uso da IA continua se expandindo e hoje permite a identificação de surtos de doenças infecciosas, de doenças raras, interpretação de exames como tomografia computadorizada e ressonância magnética (30).

Outro avanço é a possibilidade de análise de dados não estruturados como texto, imagens, áudio, vídeo, e-mails postagens de mídias sociais, que tornou possível a realização do presente trabalho. Na análise de imagens são utilizadas redes neurais convolucionais, permitindo a aplicação de IA na radiologia, patologia, endoscopia e ultrassom (31).

Em cardiologia, a área de AM, subárea da IA, também encontra ampla aplicação como mostrou uma revisão (22). Nela, Souza Filho *et al.* citam os vários modelos de IA e as respectivas utilizações. Uma delas é a detecção de arritmias por meio do uso de dispositivos vestíveis. Outra, a avaliação de desfechos na síndrome coronariana aguda (SCA). Além disso, a IA foi utilizada para determinar qual melhor plano da valva mitral na segmentação ventricular esquerda nos exames de Tomografia Computadorizada por Emissão de Fóton Único (SPECT) e para avaliar a presença ou ausência de SCA em indivíduos com dor torácica em pronto socorro (22). Outras utilizações vão da detecção de disfunção ventricular até a determinação da idade cardiovascular, passando por diagnóstico de fibrilação atrial (FA) silenciosa, cardiomiopatia hipertrófica e níveis séricos de potássio (32).

Friedrich *et al.*, em uma revisão sistemática avaliou as publicações sobre IA aplicada à cardiologia entre 2000 e 2020. O número de publicações entre 2000 e 2015 foi de 0,1% passando para 16,2% até marco de 2020, um aumento de 162 vezes. Os países que mais publicaram nessa área são EUA, Canada, Inglaterra, Alemanha, França, Austrália e China. Dos estudos avaliados, 42% são diagnósticos e 43% prognósticos (33).

### 3.3.6 Aplicação da IA na IC

A IA tem sido largamente aplicada às doenças cardiovasculares e, especialmente, à insuficiência cardíaca, tanto para diagnóstico, quanto para predição de desfechos.

Em estudo de Lima *et al.*, realizado no Brasil, um algoritmo de IA foi aplicado a ECGs para avaliar idade cardiovascular como preditor de mortalidade. Foram avaliados ECGs coletados pela Rede de Telessaúde de Minas Gerais do estudo *Clinical Outcomes in Digital Outcomes (CODE Study)* com 1.558.415 pacientes de 811 municípios de Minas Gerais. Os indivíduos com idade cardiovascular maior que 8 anos em relação à idade cronológica tiveram maior mortalidade quando comparados aos indivíduos que tinham idade cardiovascular menor que 8 anos em relação à idade cronológica (34).

Em um trabalho, Olsen *et al.*, avaliaram o uso de IA na IC no que concerne ao diagnóstico, classificação e predição de desfechos. No diagnóstico, algoritmos de ML têm sido aplicados ao ECG e ao ECO, mostrando melhor desempenho. Neste estudo foram utilizadas técnicas de ML para identificar variáveis clínicas e ecocardiográficas preditoras de desfechos clínicos, tendo sido identificadas 6 que resultaram em um escore com AUC de 0,841, melhor que o escore atualmente proposto de Sociedade Europeia de Cardiologia. Outro estudo utilizou um algoritmo de AM e de processamento da linguagem natural (PLN) para identificar com IC a partir dos dados do prontuário eletrônico e da avaliação do texto das anamneses dos pacientes, obtendo sensibilidade de 0,953 e VPP de 0,975 (35).

Choi *et al.* utilizaram o conceito de decisão clínica baseada em computador da década de 60 e desenvolveram um Sistema de Suporte a Decisões Clínicas com IA – *Clinical Decision Support System (AI-CDSS)*. Utilizando uma coorte retrospectiva com dados de 1198 indivíduos – 600 para treinamento e 598 para validação - os autores fizeram uma hibridização das recomendações clínicas para diagnóstico de IC com o modelo preditivo orientado por AM. A precisão diagnóstica foi de 90%, 88,5% e 98,3% para as abordagens dos especialistas, do modelo preditivo do ML e para o AI-CDSS, respectivamente, sendo que a abordagem híbrida teve 0,94 de sensibilidade e 0,99 de especificidade (36).

Em uma revisão, Yasmin *et al.*, avaliaram, entre outros, o uso da IA para predição de mortalidade. Para a sobrevivência em 5 anos, um algoritmo de AM obteve 80% de precisão em comparação com os médicos, que obtiveram 60% (37). Outro estudo, utilizando uma rede neural não-supervisionada, classificou indivíduos com IC em 6 fenogrupos o que pode tornar o tratamento mais individualizado (38).

Ranka *et al.* exploraram a aplicação da IA em sistemas de alerta que previam a deterioração clínica de pacientes internados. Um algoritmo treinado para detectar hipotensão, com 10 minutos de antecedência do evento, obteve uma AUC de 0,89 em um teste externo. Outro algoritmo conseguiu uma AUC de 0,88 na predição de desfechos em 18 meses em pacientes com IC (39).

Também tem sido estudada, com resultados promissores, a aplicação da IA ao ECG para diagnóstico de IC, bem como no prognóstico.

Attia *et al.* aplicaram um algoritmo de IA em ECG para prever disfunção ventricular esquerda em indivíduos assintomáticos. Esse estudo foi realizado na *Mayo Clinic* com 44959 pacientes. ECGs e ECOs foram pareados e submetidos a uma RNC, um algoritmo de aprendizado profundo, que foi treinado para identificar padrões no ECG que predissessem a presença de disfunção ventricular, definida como FEVE  $\leq 35\%$ . Após esse treinamento, o algoritmo foi aplicado aos ECGs de 52870 pacientes, obtendo-se uma sensibilidade e especificidade de 86,3% e 85,7%, respectivamente, com uma área sob a curva ROC (AUC-ROC) de 0,93. Nos pacientes sem disfunção ventricular e que foram positivamente identificados pela IA, houve 4 vezes mais risco de desenvolvimento de disfunção ventricular quando comparados aos indivíduos negativos (40).

No Brasil, Brito *et al.*, realizaram a validação desse algoritmo em pacientes com doença de chagas, utilizando uma coorte do Centro de Pesquisa em Medicina Tropical São Paulo-Minas Gerais (Sa-Mi-Trop). Nesse estudo, foram avaliados 1304 pacientes chagásicos, dos quais 93 (7,1%) tinham disfunção sistólica do ventrículo esquerdo, definida como fração de ejeção menor que  $< 40\%$  ao ECO. O algoritmo de IA identificou esses pacientes com um OR de 63,3, sensibilidade de 73%, especificidade de 83% e AUC-ROC de 0,839 (41).

Cho *et al.* utilizaram uma RNC na análise de 39371 ECGs de 17127 indivíduos, pareados com seus respectivos ECOs, que foram realizados dentro de um prazo máximo de 30 dias. O desfecho avaliado foi FEVE  $< 40\%$ . O estudo foi dividido em duas etapas, de validação interna e externa. Durante a primeira etapa, realizada em um hospital escola, a AUC, sensibilidade, especificidade e acurácia foram de 0,913; 0,905; 0,756 e 0,775, respectivamente. Na fase de validação externa, realizada em um hospital geral, esses parâmetros foram de 0,961; 0,915; 0,911 e 0,911, respectivamente. Nesse estudo também foi avaliado o ECG de derivação única com AUC de 0,874 e 0,929 nas etapas de validação interna e externa, respectivamente (42).

Akbilgic *et al.* compararam o poder de prever insuficiência cardíaca em 10 anos de dois estudos, *Atherosclerosis Risk in Communities (ARIC)* e do *Framingham Heart Study*

(FHS) com um algoritmo de RNC que utilizou apenas dados de ECG de 12 derivações. O modelo de RNC obteve uma Área sob a Curva *Receiver Operator Characteristic Curve* (ASC-ROC) de 0,756 que não foi estatisticamente diferente da predição pelo modelo do FHS, 0,778. No entanto, o modelo da RNC foi estatisticamente diferente da ASC-ROC do modelo do ARIC, 0,778. Curiosamente, a ASC-ROC usando a RNC aplicada apenas aos dados da derivação DI foi de 0,754, semelhante ao modelo de 12 derivações (43).

Dados de um estudo de Chen *et al.* que também avaliou o desempenho de uma RNC para diagnóstico de FEVE  $\leq 35\%$  com bons resultados, mostrou que os pacientes falsos positivos foram mais suscetíveis a *Major Adverse Cardiovascular Outcomes* (MACE) quando comparados aos verdadeiros negativos (FEVE  $> 50\%$ ). O *Hazard Ratio* (HR) geral foi de 1,46 (IC 95% 1,35 – 1,47) para mortalidade por todas as causas; 1,88 (IC 95% 1,44 – 2,47) para morte cardiovascular; 1,94 (IC 95% 1,67 – 2,25) para IC; 2,61 (IC 95% 1,48 – 4,61) para morte súbita cardíaca e 2,05 (IC 95% 1,58 – 2,64) para morte por infarto agudo do miocárdio (44).

Grun *et al.* em uma metanálise avaliaram estudos publicados entre 2011 e 2021 que utilizaram a IA aplicada ao ECG para detecção de IC. Todos estudos definiram como desfecho primário FEVE  $\leq 35\%$ . Foram incluídos 5 estudos, totalizando mais de 579 mil ECGs, cuja sensibilidade variou entre 83 e 100% e a especificidade ficou entre 86 e 100%. Foi obtida uma ASC-ROC de 0,987 e *Diagnostic Odds Ratio* (DOR) de 7,59 (45). Já LI XM *et al.* realizaram uma metanálise de 11 estudos, obtendo sensibilidade e especificidade agrupada de 0,95 e 0,98, respectivamente. A ASC-ROC foi de 0,986 com DOR de 831,51 (46). Nos dois estudos os autores chamam atenção para a heterogeneidade dos estudos como umas das principais limitações e para a necessidade de padronização dos métodos nessa área.

Por fim, um estudo publicado esse ano por Sangha *et al.* avaliou o desempenho de um algoritmo para detecção de DSVE. O algoritmo de RNC foi desenvolvido e validado no *Yale New Haven Hospital* e utilizou a base de dados do ELSA-Brasil, entre outras, na fase de validação. Ao todo foram avaliados 385601 ECGs pareados com ECOs realizados no máximo 15 dias após o ECG. O objetivo foi prever FEVE  $< 40\%$ , sendo considerado positivo quando a predição do algoritmo fosse maior que 10% de probabilidade de DSVE (sensibilidade 90%). Na fase de validação interna a ASC-ROC foi de 0,91 com OR 27,5. Na validação externa, variou entre 0,90 e 0,95 nos vários cenários testados. Entre os falsos positivos, o HR para desenvolvimento de DSVE foi de 3,9 em um seguimento de 3,2 anos e de 2,3 quando ajustado para idade, sexo e à FEVE calculada no início do estudo. Especificamente na coorte do ELSA-Brasil, a ASC-ROC, sensibilidade, especificidade, VPP e VPN foram 0,949; 0,700; 0,976; 0,256 e 0,996, respectivamente. Uma novidade desse estudo foi o uso de mapas de calor

(*gradient-weighted class activation mapping*) para identificar quais partes do ECG são mais relevantes para a predição do algoritmo. De acordo com os resultados, as derivações V2 e V3 (Figura 5) foram as mais utilizadas para discriminar DSVE (47).

A tabela 1 a seguir resume os dados encontrados nos estudos mencionados que avaliaram o uso de IA aplicado ao ECG para detecção de DSVE.

**Tabela 1** – Achados de acurácia dos estudos que avaliaram o uso de IA aplicado ao ECG para detecção de DSVE.

Estudo (Ano)	Ponto de corte da FEVE (%)	Sensibilidade (%)	Especificidade (%)	VPP	VPN	DOR	ASC - ROC	Acurácia (%)
Attia <i>et al.</i> (2019) (40)	≤ 35	86,3	85,7	-	-	-	0,93	85,7
Brito <i>et al.</i> (2021) (41)	≤ 40	73,0	83,0	25,0	97,0	-	0,839	83,0
Cho <i>et al.</i> (2021) (42)	< 40	91,5	91,1	-	-	-	0,961	91,1
Chen <i>et al.</i> (2022) (44)	< 35	86,9	89,6	-	-	-	0,947	-
Grün <i>et al.</i> (2021) (45)	≤ 40	83-100	86-100	-	-	7,59	0,987	-
Li <i>et al.</i> (2022) (46)	≤ 35	95,0	98,0	-	-	831,51	0,986	-
Sangha <i>et al.</i> (2023) (47)	< 40	89,0	77,0	26,0	99,0	27,5	0,91	-

Fonte: Elaboração do autor. FEVE: Fração de Ejeção do Ventrículo Esquerdo; VPP: Valor preditivo positivo; VPN: Valor preditivo negativo; DOR: *Diagnostic Odds Ratio*; ASC-ROC: Área Sobre a Curva - *Receiver operating characteristic*

**Figura 5** – *Gradient-weighted class activation mapping* destacando as derivações V2 e V3.



Fonte: Detection of Left Ventricular Systolic Dysfunction From Electrocardiographic Images. *Circulation*. 2023 Jul 25; CIRCULATIONAHA, Sangha et-al

Esse mapa de calor mostra regiões do ECG que foram mais utilizadas pelo algoritmo – quanto mais vermelha, maior a importância daquela região para estimar a probabilidade de disfunção sistólica do ventrículo esquerdo.

Partindo desse corpo de conhecimento, o presente estudo pretende avaliar o desempenho de um algoritmo de IA para detecção de DSVE em uma população brasileira oriunda da coorte do estudo ELSA-Brasil quando comparado às alterações eletrocardiográficas tradicionais representadas pela AME. Este algoritmo foi desenvolvido por Sangha *et al.* no Yale New Haven Hospital, EUA. Nossa hipótese é que o algoritmo de IA apresenta um melhor desempenho do que as AME. Na prática clínica, tais alterações levam à suspeição de DSVE e ensejam extensão propedêutica, principalmente a realização de ECO.

## 4 OBJETIVOS

### 4.1 Objetivo geral

Comparar a acurácia diagnóstica entre um algoritmo de inteligência artificial aplicado ao ECG para predição de disfunção ventricular esquerda e as AME.

### 4.2 Objetivo geral

- ✓ Comparar a sensibilidade, especificidade, acurácia, VPP, VPN, RVP, RVN E DOR do algoritmo de IA utilizado e das AME para predição de DSVE;
- ✓ Calcular a ASC-ROC do algoritmo.

## 5 MATERIAIS E MÉTODOS

### 5.1 Participantes

Os participantes do estudo são indivíduos do ELSA-Brasil que é um estudo de coorte, prospectivo, multicêntrico, iniciado em 2008. Esse estudo acompanha funcionários de seis universidades (Universidades federais da Bahia, Espírito Santo, Minas Gerais, e Rio Grande do Sul, Universidade de São Paulo, CEFET-MG) e 1 instituto de pesquisa (Fundação Oswaldo Cruz), de ambos os sexos, com idade entre 35 e 74 anos. O ELSA-Brasil acompanha 15105 participantes com o objetivo de contribuir para o conhecimento sobre o desenvolvimento e progressão de doenças crônicas, em particular o DM e as DCV.

Para o presente estudo foram selecionados os participantes da linha de base, que possuíam ECO e ECG válidos, além de valores de predição de disfunção sistólica do ventrículo esquerdo (DSVE) estimadas por um algoritmo de inteligência artificial (IA).

### 5.2 Definição das variáveis e testes do estudo

A variável explanatória é o ECG avaliado por meio das AME e pela IA, de acordo com o algoritmo da RNC e a variável de desfecho é a FEVE  $< 40\%$ , sendo calculada pelo ECO, método de eleição. As covariáveis são idade, gênero, colesterol total, HDL colesterol, pressão arterial sistólica, hipertensão arterial, tabagismo, diabetes melitos, glicemia de jejum, dislipidemia, doença vascular conhecida (doença coronariana, acidente vascular encefálico, doença arterial periférica).

#### 5.2.1 Desenvolvimento da Rede Neural Convolutacional

Para o desenvolvimento da rede 385.601 ECGs foram pareados com seus respectivos ECOs. A validação interna foi realizada com internos do *Yale New Haven Hospital*. Já validação externa foi realizada com indivíduos oriundos de cinco centros, entre eles o ELSA-Brasil. Foi utilizado um modelo de RNC baseada na arquitetura EfficientNet-B3 para avaliação dos ECGs dos participantes. Esse tipo de arquitetura requer imagens de 300 x 300 pixels e inclui 384 camadas e tem mais de 10 milhões de parâmetros treináveis. Tal algoritmo foi desenvolvido e validado no *Yale New Haven Hospital* entre 2015 e 2021 (47).

Tradicionalmente os algoritmos desenvolvidos para avaliação de ECG utilizam o sinal bruto, enquanto o algoritmo utilizado no nosso estudo utiliza a imagem do ECG. Todos os exames sofreram tratamento prévio sendo convertidas para imagens com resolução de 300 x 300 pixels em escala de cinza. As RNC têm se mostrado particularmente úteis no estudo de dados não estruturados como imagens e áudio. O algoritmo, após avaliação do ECG, informa um valor de probabilidade (0 -1) de haver ou não DSVE e, no presente estudo, foi considerado um teste positivo quando a predição informada fosse maior do que 0,1 (10%). Esse ponto de corte para a probabilidade teve sensibilidade de 90% (47).

### 5.2.2 Obtenção do eletrocardiograma

Foi realizado o ECG convencional de 12 derivações a partir de um aparelho digital (Atria 6100, Burdick, Cardiac Science Corporation, EUA). As leituras de frequência cardíaca, duração, amplitude e eixos das ondas P, QRS e T, além dos intervalos QT, QTc e da dispersão de QT foram feitas de maneira automatizada. Para o posicionamento dos eletrodos precordiais, primeiro obteve-se o V4 e, a partir dele, os demais eletrodos foram posicionados. O Centro de Leitura (CL) de Eletrocardiografia localizado no Centro de investigação de MG (CI MG) foi o responsável pela leitura centralizada de todos os ECGs do ELSA, seguindo a padronização do Código de Minnesota (48). Devido à complexidade de leitura e codificação, foi criado um Centro de Leitura de ECG (CL-ECG), para que fossem garantidas a qualidade e uniformidade das análises. Previamente à implantação do CL-ECG, dois dos maiores centros de leitura de ECG do mundo foram visitados, o EPICARE na Carolina do Norte, EUA e o CARE, em Glasgow, na Escócia. Para garantir a acurácia e confiabilidade dos ECGs foram realizados treinamento e posterior certificação dos técnicos envolvidos, nos CIs e nos CLs foram feitos procedimentos para avaliar a qualidade dos exames obtidos (48).

### 5.2.3 Obtenção do ecocardiograma

Considerou-se DSVE aqueles participantes que apresentaram FEVE < 40% ao ECO, exame de escolha para cálculo desse parâmetro. Dos métodos disponíveis para estimar a FEVE, o ECO é o mais acessível. Os valores da FEVE não foram cegados. No ELSA-Brasil, o ECO foi realizado de maneira aleatória em 10% dos participantes, e em todos os maiores de 55 anos. A aquisição de imagens foi feita por aparelhos Aplio XG (Toshiba), utilizando transdutor

setorial de 2,5Hz. As imagens eram então encaminhadas ao Picture Archiving and Communication System (PACS) do ELSA e acessadas pelo CL ecocardiografia (CI RS) (48).

Os exames foram obtidos por ecocardiografistas conforme protocolo de aquisição padronizado, em consonância com recomendações vigentes para pesquisa. A análise envolveu a avaliação qualitativa dos resultados do ecocardiograma, juntamente com a medição de parâmetros quantitativos para determinar os desfechos de interesse no estudo ELSA. Isso incluiu a avaliação do tamanho e da geometria do ventrículo esquerdo (VE), o tamanho do átrio esquerdo, a função sistólica e diastólica do VE, a detecção de disfunção segmentar, a identificação de lesões valvulares, a avaliação da degeneração fibrocálcica e a medição da espessura da gordura epicárdica (48). A FEVE foi calculada utilizando o método Teichholz.

### 5.3 Análise estatística

A descrição das variáveis foi feita utilizando mediana com intervalo interquartil para as variáveis de distribuição não-normal e frequência para variáveis categóricas.

Foram realizados também cálculos de sensibilidade, especificidade, valor preditivo positivo (VPP), valor preditivo negativo (VPN), acurácia, *Diagnostic Odds Ratio* (DOR), RVP, RVN para o algoritmo e para as AME. Para o algoritmo também foi calculada a ASC-ROC.

O software utilizado para as análises estatísticas foi o IBM SPSS *Statistiscs*, versão 21.

### 5.4 Considerações éticas

O estudo do qual origina nossa análise transversal aninhada foi aprovado pelo comitê de ética sob parecer n.º ETIC 186/06.

Os termos de consentimento livre e esclarecido foram obtidos de todos os indivíduos em duas vias como prevê a resolução 196/96 do Conselho Nacional de Saúde e somente após a aposição de assinatura foram iniciados os procedimentos de avaliação.

## 6 RESULTADO E DISCUSSÃO (ARTIGO)

### Uso da inteligência artificial (IA) aplicada ao eletrocardiograma (ECG) para diagnóstico de disfunção sistólica ventricular esquerda (DSVE) e avaliação da ASC-ROC

Wilton Batista de Santana Júnior (1); Marcelo M. Pinto-Filho, MD, MSc (2); Murilo Foppa, MD, PhD; Sandhi M. Barreto, MD, PhD (3); Luana Giatti, MD, PhD; Antonio L. P. Ribeiro, MD, PhD (2) e (3)

(1) Programa de pós-graduação em Infectologia e Medicina Tropical da Faculdade de Medicina da Universidade Federal de Minas Gerais (UFMG)

(2) Serviço de Cardiologia e Cirurgia Cardiovascular do Hospital das Clínicas da UFMG

(3) Faculdade de Medicina da UFMG

### RESUMO

**FUNDAMENTO:** a insuficiência cardíaca é uma doença associada a importante morbidade. O eletrocardiograma (ECG) é um dos exames utilizados na avaliação da IC, sendo de baixo custo e amplamente disponível. **OBJETIVO:** Avaliar o desempenho de um algoritmo de inteligência artificial (IA) aplicado ao ECG na detecção de IC e o comparamos ao poder preditivo das alterações eletrocardiográficas maiores (AME). **MÉTODOS:** estudo transversal de acurácia diagnóstica. Todos os participantes são oriundos do Estudo Longitudinal da Saúde do Adulto (ELSA-Brasil), e possuíam ECG e ecocardiograma (ECO) válidos além de valores de probabilidade para disfunção sistólica do ventrículo esquerdo (DSVE) estimados pelo algoritmo. O desfecho avaliado foi fração de ejeção do ventrículo esquerdo (FEVE) < 40% ao ECO. Foram calculados sensibilidade, especificidade, valor preditivo positivo (VPP), valor preditivo negativo (VPN), razão de verossimilhança positivo (RVP), razão de verossimilhança negativa (RVN), diagnostic odds ratio (DOR) para o algoritmo e para as AME e área sob a curva ROC (ASC-ROC) para o algoritmo. **RESULTADOS:** Na amostra final de 2567 indivíduos, a prevalência de FEVE < 40% foi de 1,13% (29 indivíduos). Os valores obtidos de sensibilidade, especificidade, VPP, VPN, RVP, RVN e DOR para o algoritmo foram de 0,690; 0,976; 0,244; 0,996; 27,6; 0,32 e 88,74, respectivamente. Para as AME, 0,172; 0,837; 0,012; 0,989; 1,09; 0,990 e 1,07, respectivamente. A ASC-ROC do algoritmo para predição de FEVE < 40% foi de 0,947 (IC 95% 0,913 – 0,981). **CONCLUSÃO:** A IA apresentou bom desempenho para detecção de DSVE e pode ser usada como ferramenta de triagem de DSVE. **Palavras-chave:** inteligência artificial; insuficiência cardíaca; disfunção sistólica do ventrículo esquerdo; eletrocardiograma; ELSA-Brasil.

### INTRODUÇÃO

A insuficiência cardíaca (IC) está entre as 3 principais causas de doenças cardiovasculares no mundo (1). Trata-se de uma síndrome complexa com alta morbidade e custos para o sistema de saúde (2-4), possuindo alta taxa de mortalidade intra-hospitalar (1,6,7). O ecocardiograma (ECO) é ferramenta de grande validade para o diagnóstico, permitindo o

cálculo da fração de ejeção do ventrículo esquerdo (FEVE). Este parâmetro é fundamental para classificação em IC com fração de ejeção reduzida (ICFEr – FEVE < 40%), levemente reduzida ou intermediária (ICFEi – FEVE entre 40 e 49%) ou preservada (ICFEp – FEVE ≥ 50%) e possui implicações terapêuticas e prognósticas (4,5).

Apesar de o ECO ser a principal ferramenta para diagnóstico e avaliação da IC, em países de média e baixa renda a disponibilidade dele para uso disseminado à toda população elegível ainda é um desafio. Uma das estratégias para superar este problema é o aprimoramento de ferramentas mais acessíveis para avaliar pacientes em risco que se beneficiariam de propedêutica adicional (6). Dentre estas ferramentas, tradicionalmente o ECG, exame de baixo custo e amplamente disponível, é muito utilizado na avaliação inicial quando há suspeita de IC. Entretanto, para o diagnóstico dessa síndrome, possui acurácia limitada (3,4,7), necessitando de aprimoramentos para se prestar a este fim.

O uso e a disseminação da IA tem aumentado nos últimos anos, não sendo diferente na área da saúde (8). Dentre as áreas da IA, o aprendizado de máquina (AM) ou machine learning tem ganhado destaque nas aplicações na área médica (9,10). O número de estudos em IA aplicado à cardiologia aumentou significativamente nos últimos anos, (11) com aplicações possíveis na avaliação da idade cardiovascular (12), níveis séricos de potássio, detecção de fibrilação atrial (FA) silenciosa, detecção de cardiomiopatia hipertrófica (13), predição de hipotensão em pacientes de unidades de terapia intensiva (UTI) (14) e diagnóstico de IC a partir da leitura do ECG (15-24).

No presente trabalho foi avaliada a acurácia de um algoritmo de rede neural convolucional (RNC), (25, 26) utilizado para prever, a partir da leitura do ECG, indivíduos que possuam DSVE, definida como FEVE < 40%. O desempenho do algoritmo foi comparado ao das AME, uma vez que, na prática clínica, tais alterações levam à suspeição de DSVE e ensejam extensão propedêutica, principalmente a realização de ECO.

## **MÉTODOS**

### **Desenho do estudo e participantes**

Trata-se de um estudo transversal de acurácia diagnóstica. Os participantes são oriundos do Estudo Longitudinal do Adulto (ELSA-Brasil) (27). Foram incluídos todos os indivíduos que tivessem ECG e ecocardiograma (ECO) válidos além dos dados de probabilidade de DSVE estimada pelo algoritmo. Os indivíduos foram avaliados consecutivamente, não havendo randomização e cegamento dos valores de FEVE.

## Desenvolvimento da Rede Neural Convolutacional

Para o desenvolvimento da rede 385.601 ECGs foram pareados com seus respectivos ECOs. A validação interna foi realizada com internos do *Yale New Haven Hospital*. Já validação externa foi realizada com indivíduos oriundos de cinco centros, entre eles o ELSA-Brasil. Foi utilizado um modelo de RNC baseada na arquitetura *EfficientNet-B3* para avaliação dos ECGs dos participantes. Esse tipo de arquitetura requer imagens de 300 x 300 pixels e inclui 384 camadas e tem mais de 10 milhões de parâmetros treináveis. Tal algoritmo foi desenvolvido e validado no *Yale New Haven Hospital* entre 2015 e 2021.

Tradicionalmente os algoritmos desenvolvidos para avaliação de ECG utilizam o sinal bruto, enquanto o algoritmo utilizado no nosso estudo utiliza a imagem do ECG. O algoritmo, após avaliação do ECG, informa um valor de probabilidade (0 -1) de haver ou não DSVE, sendo considerado um teste positivo quando a predição informada pelo algoritmo fosse maior do que 0,1 (10%). Como neste estudo o algoritmo foi utilizado para fins de triagem, optou-se por este ponto de corte, que no artigo original ofereceu sensibilidade de 90% (24).

## Obtenção do eletrocardiograma

Foi realizado o ECG convencional de 12 derivações utilizando-se um aparelho digital (Atria 6100, Burdick, Cardiac Science Corporation, EUA). As leituras de frequência cardíaca, duração, amplitude e eixos das ondas P, QRS e T, além dos intervalos QT, QTc e da dispersão de QT foram feitas de maneira automatizada. O Centro de Leitura (CL) de Eletrocardiografia localizado no Centro de investigação de MG (CI MG) foi o responsável pela leitura centralizada de todos os ECGs do ELSA, seguindo a padronização do Código de Minnesota (27). Para garantir a qualidade de uniformidade das análises a leitura e codificação dos exames, criou-se um centro de leitura de ECG (CL-ECG), precedido pela visita a dois dos maiores centros de leitura de ECG o EPICARE na Carolina do Norte, EUA e o CARE, em Glasgow, na Escócia (27).

## Obtenção do ecocardiograma

No ELSA-Brasil, o ECO foi realizado de maneira aleatória em 10% dos participantes, e para além disso, também foi feito em todos os participantes maiores de 55 anos. A aquisição de imagens foi feita por aparelhos Aplio XG (Toshiba), utilizando transdutor setorial de 2,5Hz. As imagens eram então encaminhadas ao Picture Archiving and Communication System (PACS) do ELSA e acessadas pelo CL ecocardiografia (CI RS). Os exames foram obtidos por ecocardiografistas conforme protocolo de aquisição padronizado em consonância com

recomendações vigentes para pesquisa. A leitura consistiu em análise qualitativa dos achados ecocardiográficos e mensuração de parâmetros quantitativos para definição dos desfechos de interesse do ELSA, incluindo: tamanho e geometria do ventrículo esquerdo (VE), tamanho do átrio esquerdo, função sistólica e diastólica do VE, presença de disfunção segmentar, lesões valvulares e degeneração fibrocálcica e espessura da gordura epicárdica (27). Considerou-se DSVE aqueles participantes que apresentaram FEVE < 40% ao ECO (pelo método Teichholz), exame de escolha para cálculo desse parâmetro. Dos métodos disponíveis para estimar a FEVE, o ECO é o mais acessível. Os valores da FEVE não foram cegados.

#### Análise estatística

A descrição das variáveis foi feita utilizando mediana com intervalo interquartil para as variáveis contínuas de distribuição não-normal e frequência para variáveis categóricas.

Foram realizados cálculos das seguintes métricas: sensibilidade, especificidade, valor preditivo positivo (VPP), valor preditivo negativo (VPN), acurácia, *Diagnostic Odds Ratio* (DOR), razão de verossimilhança positiva (RVP), razão de verossimilhança negativa (RVN). Para o algoritmo também foi calculada a área sob a curva ROC (ASC-ROC).

O software utilizado para as análises estatísticas foi o IBM SPSS *Statitiscs*, versão 21.

## RESULTADOS

Após aplicados os critérios de seleção na amostra total do ELSA-Brasil, dos 15105 indivíduos, 3396 possuíam ECO e ECG válidos. Desses, 2567 possuíam ECO, ECG e informação de probabilidade de IC pelo algoritmo, havendo perda de 829 indivíduos. Provavelmente, essa perda correu durante a transmissão para o centro onde os ECGs foram lidos pelo algoritmo. O fluxograma de seleção de pacientes está detalhado na Figura 1. As características clínicas dos participantes do estudo estão apresentadas na Tabela 1. A mediana da idade dos participantes foi de 62 anos tanto no grupo dos homens (45,4%) quanto nos das mulheres. Estas tiveram níveis séricos mais altos tanto de HDL-c quanto de colesterol total. Já entre os homens verifica-se maior prevalência de dislipidemia, tabagismo, diabetes melitus, acidente vascular cerebral, e doença cardiovascular autorreferida. A prevalência de FEVE < 40% foi de 1,13%. A característica clínica dos 15105 participantes do ELSA-Brasil está disponibilizada na tabela suplementar 1.

A prevalência das AME está descrita na Tabela 2. As principais anormalidades foram alteração maior de ST-T isolada, alteração maior de onda Q (IAM antigo/prevalente) e o BRD completo, representando 6,5%, 3,9% e 3,1% das alterações, respectivamente.

A distribuição da FEVE de acordo com a predição do algoritmo para DSVE está na Tabela 3. Dos 29 indivíduos com DSVE, o algoritmo identificou corretamente 20. Já na Tabela 4 está a distribuição da FEVE de acordo com a presença de AME. Dos 29 indivíduos com DSVE apenas 5 apresentavam AME.

Os valores da sensibilidade, especificidade, VPP, VPN, RVP, RVN e DOR para o algoritmo e para as AME estão apresentados na Tabela 5. Para o algoritmo também foi calculada a ASC-ROC (Figura 2). O algoritmo apresentou valores maiores, quando comparado à AME, para sensibilidade (0,690 versus 0,172), especificidade (0,976 versus 0,837), RVP (27,6 versus 1,09) e DOR (88,74 versus 1,07). Para o algoritmo também foi calculado a ASC-ROC, 0,947 (0,913-0,981).

## DISCUSSÃO

Neste estudo com 2567 indivíduos, o desempenho do algoritmo de IA para predição de DSVE mostrou melhor desempenho em relação às AME conforme demonstrado pelos testes de acurácia e a ASC-ROC. Para a sensibilidade, o algoritmo obteve desempenho significativamente maior do que as AME, 69,0% *versus* 17,2%, respectivamente. Para especificidade, o algoritmo também apresentou melhor performance, 97,6% *versus* 83,7% para as AME. A RVP para o algoritmo foi de 27,6, aumentando expressivamente a probabilidade pós teste de DSVE na presença de teste positivo. Já para as AME o valor de RVP foi 1,09, ou seja, sua presença tem impacto quase nulo na probabilidade pós teste para DSVE. Outra métrica bastante expressiva para o algoritmo foi o DOR com valor de 88,74, significando que um indivíduo com DSVE possui 88 vezes mais chances de ter um teste positivo pelo algoritmo. Por fim, a ASC-ROC do algoritmo foi de 0,947, mostrando possuir boa capacidade de discriminar indivíduos doentes dos não-doentes.

Supomos algumas razões para o algoritmo apresentar melhor desempenho quando comparado às AME. Primeiro e como já mencionado, as RNC são utilizadas no reconhecimento de padrões de imagens e avaliam alterações diferentes (ou padrões) das que tradicionalmente os médicos levam em consideração. É provável que a explicabilidade deste modelo não passe pela análise das alterações eletrocardiográficas tradicionalmente reconhecidas na prática clínica, dada a baixa acurácia dessas no nosso estudo. Além disso, o algoritmo consegue

estabelecer relações entre esses padrões, conferindo maior poder às suas predições. Segundo o algoritmo utilizado neste estudo é altamente específico, ou seja, ele foi projetado para avaliar o ECG (*input*) e fornecer um valor de predição (*output*). Isso aliado a *hardwares* mais robustos e à grande quantidade de dados disponíveis (*big data*) confere grande poder computacional culminando em análises mais precisas do ECG. Finalmente, uma RNC aprende a partir de milhares de ECGs, com mínima perda de dados. Por outro lado, um médico, ao longo do seu treinamento, é exposto a um número de ECGs muito menor e boa parte dos dados visualizados se perde devido a uma limitação natural da memória humana.

Outros estudos avaliaram o desempenho da IA para diagnóstico de DSVE (FEVE < 40%) apresentando também resultados semelhantes. Attia *et al.* em estudo realizado na *Mayo Clinic* que envolveu ECGs de mais 98 mil pacientes encontraram sensibilidade, especificidade e ASC-ROC de 86,3%, 85,7% e 0,93, respectivamente (18). Cho *et al.* avaliaram 3470 ECGs de 2908 pacientes encontrando sensibilidade, especificidade e ASC-ROC de 0,915; 0,911 e 0,961, respectivamente (19). Finalmente, Sangha *et al.*, utilizando o algoritmo avaliado no nosso estudo aplicado a mais de 385 mil ECGs de 6 centros diferentes, um deles o ELSA-Brasil, obtendo sensibilidade, especificidade e ASC-ROC de 0,891; 0,900 e 0,949, respectivamente. Além disso, chegaram à conclusão de que as regiões de V2 e V3 foram as mais importantes para o cálculo de predição de DSVE (24).

Nosso trabalho apresenta alguns pontos fortes. Primeiro, o ELSA-Brasil tem um banco de dados robusto, contando com 15105 indivíduos. Isso permitiu que tivéssemos um grande tamanho amostral (2567 participantes), conferindo solidez aos nossos achados. Segundo, as variáveis utilizadas possuem fidedignidade uma vez que foram coletadas por equipe devidamente treinada nos CLs. Terceiro, no nosso estudo a prevalência de DSVE foi de 1,13%, portanto similar à prevalência no Brasil. Nos estudos avaliados para este trabalho, a prevalência de DSVE foi pelo menos 5 vezes maior do que na nossa população. Portanto, o algoritmo mostrou bom desempenho, mesmo em um cenário de baixa prevalência da doença. Entretanto, a baixa prevalência pode superestimar o VPN obtido. Quarto, o ECG é um exame de baixo custo e amplamente disponível o que possibilitaria o uso do algoritmo em larga escala. No Brasil há cerca de 42 mil Unidades Básicas de Saúde (UBS) e mais de 460 Unidade de Pronto Atendimento (UPA). Em praticamente todas elas há um ou mais eletrocardiógrafos. De acordo com o Programa Nacional Telessaúde Brasil Redes existem 6 mil pontos de Telessaúde. Portanto, os ECGs das UBSs e das UPAs poderiam ser transmitidos aos pontos de Telessaúde e serem avaliados pelo algoritmo de IA, funcionando com um programa de triagem para IC. Aqueles indivíduos que fossem classificados como positivos pelo algoritmo, seriam então

encaminhados para avaliação cardiológica e teriam prioridade para realização de ECO. Quinto, ele é um dos primeiros estudos avaliando o uso de IA para diagnóstico de IC em uma população brasileira. E, sexto, ele compara a acurácia das AME à da IA no diagnóstico de DSVE.

Nosso estudo apresenta algumas limitações. Primeiro, não sabemos como será o desempenho do algoritmo diante de ECGs que não sejam coletados com o mesmo rigor técnico do ELSA-Brasil. O correto posicionamento dos eletrodos cardíacos é fundamental para uma análise fidedigna. Segundo, os exames analisados são de pacientes ambulatoriais, portanto desconhecemos o desempenho do algoritmo no contexto de emergência, sendo necessário estudos nesse sentido. Terceiro, realizamos uma análise retrospectiva, não tendo sido avaliado o intervalo de tempo entre a aquisição do ECG e do ECO. Para desenvolvimento do algoritmo é necessária uma fase de treinamento na qual são pareados ECGs e ECOs para que o algoritmo detecte padrões e crie suas regras para o cálculo de probabilidade de DSVE. Portanto, o intervalo de tempo entre ECG e ECO deve garantir que esses exames reflitam a atual condição clínica do paciente. Uma das maneiras de se resolver essa questão é realizando estudos prospectivos no qual o tempo entre a realização entre os exames seja definido.

## **CONCLUSÃO**

A utilização de IA associada ao ECG tem potencial para impactar positivamente o cenário da IC no país. Sua utilização poderia permitir o diagnóstico precoce da IC bem como o tratamento, com potencial redução na mortalidade e morbidade (custos com internações, absenteísmo, aposentadorias por invalidez, melhora da qualidade de vida) por DCVs.

## **LEGENDAS DAS FIGURAS**

Figura 1 – Fluxograma de seleção dos participantes

Figura 2 – Área sob a curva ROC do algoritmo de RNC para predição maior que 10% de FEVE < 40%

## TABELAS

**Tabela 1** – Características clínicas dos participantes do estudo

	<b>População geral</b>	<b>Homens</b>	<b>Mulheres</b>
Número	2567	1166 (45,4%)	1401 (54,6%)
Idade (anos), mediana e IQ (25-75)	52 (56 – 66)	62 (56,0 – 67,0)	62 (55,0 – 66,0)
Pressão arterial sistólica, mediana e IQ (25-75)	123,50 (113,00 – 136,50)	126,5 (116,37 – 139,50)	121 (110,00 – 134,50)
HDL colesterol (mg/dL), mediana e IQ (25-75)	52,90 (44,73 – 62,89)	46,54 (41,10 – 54,72)	58,35 (49,27 – 68,34)
Colesterol total (mg/dL), mediana e IQ (25-75)	198,10 (172,91 – 226,19)	192,29 (167,10 – 219,41)	202,94 178,72 – 232,00)
Glicemia de jejum (mg/dL), mediana e IQ (25-75)	107,00 (100,00 – 117,00)	110 (103,00 – 121,00)	105 (98,00 – 114,00)
Dislipidemia (%)	55,7	50,9	59,7
Hipertensão arterial sistêmica (%)	49,5	53,6	46,1
Tabagismo (%)	10,0	11,8	8,4
Diabetes Melitus (%)	21,9	26,4	18,2
Doença Arterial Periférica (%)	5,6	5,3	5,9
Acidente Vascular Cerebral (%)	1,9	2,3	1,5
Doença Cardiovascular autorreferida (%)	10,9	14,1	8,3

Fonte: Elaboração do autor.

**Tabela 2** – Alterações eletrocardiográficas maiores e suas frequências, de acordo com o código de Minnesota

<b>Alteração</b>	<b>Frequência (%)</b>
Alterações maiores de ST-T isoladas	6,5
Alterações maiores de ondas Q (IAM antigo/prevalente)	3,9
Bloqueio de Ramo Direito completo	3,1
Prolongação maior do intervalo QT	2,2
Bloqueio de Ramo Esquerdo completo	1,0
Fibrilação Atrial/Flutter	0,9
Bloqueio intraventricular inespecífico	0,9
Hipertrofia Ventricular Esquerda mais alterações de ST-T	0,8
Alterações menores de onda Q mais alterações de ST-T (IAM prévio possível)	0,4
Pré-excitação ventricular	0,1
Marcapasso artificial	0,1
Bloqueio de Ramo Direito com bloqueio divisional anterossuperior	0,1
Padrão de Brugada	0,0
Bloqueio Atrioventricular de 3o grau	0,0
Bloqueio Atrioventricular de 2o grau	0,0
Fibrilação/assistolia ventricular	0,0
Taquicardia supraventricular	0,0

Fonte: Elaboração do autor.

**Tabela 3** – Distribuição dos valores de predição do algoritmo de IA de acordo com a FEVE

		FEVE (%)	
		< 40	≥ 40
Predição do algoritmo de IA (%)	≥10	20	62
	<10	9	2476

Fonte: Elaboração do autor. IA: Inteligência artificial. FEVE: Fração de ejeção do ventrículo esquerdo

**Tabela 4** – Distribuição das alterações maiores ao ECG de acordo com a FEVE

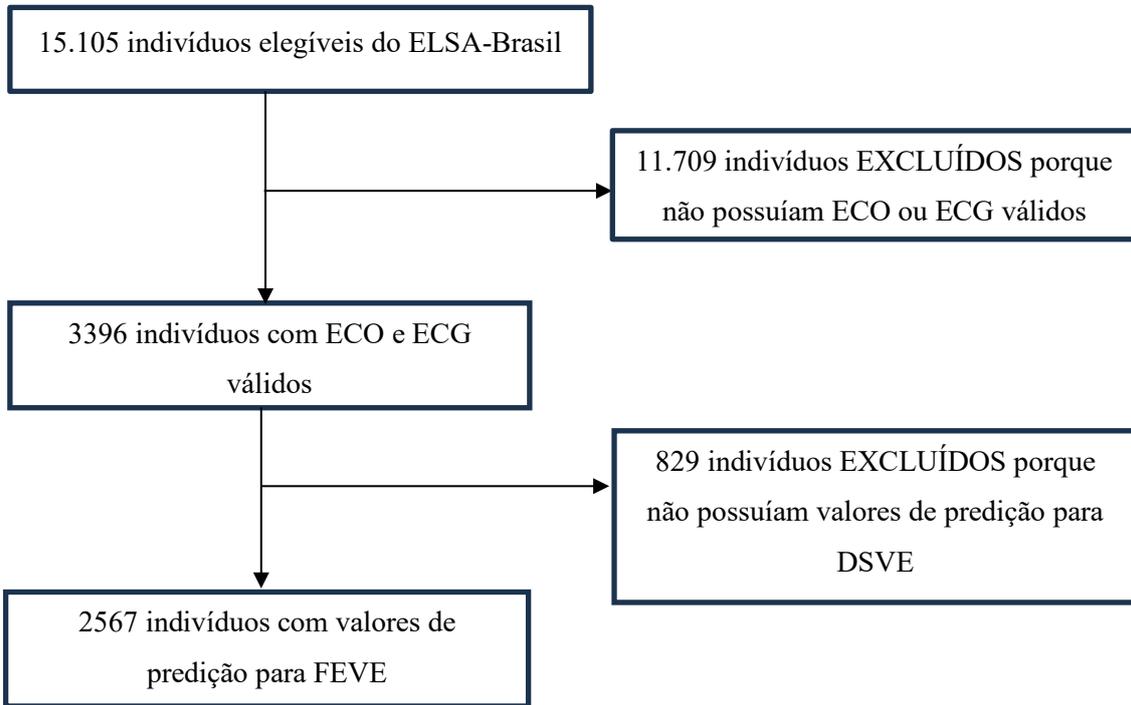
		FEVE (%)	
		< 40	≥ 40
Alterações maiores ao ECG	Presente	5	413
	Ausente	24	2125

Fonte: Elaboração do autor.

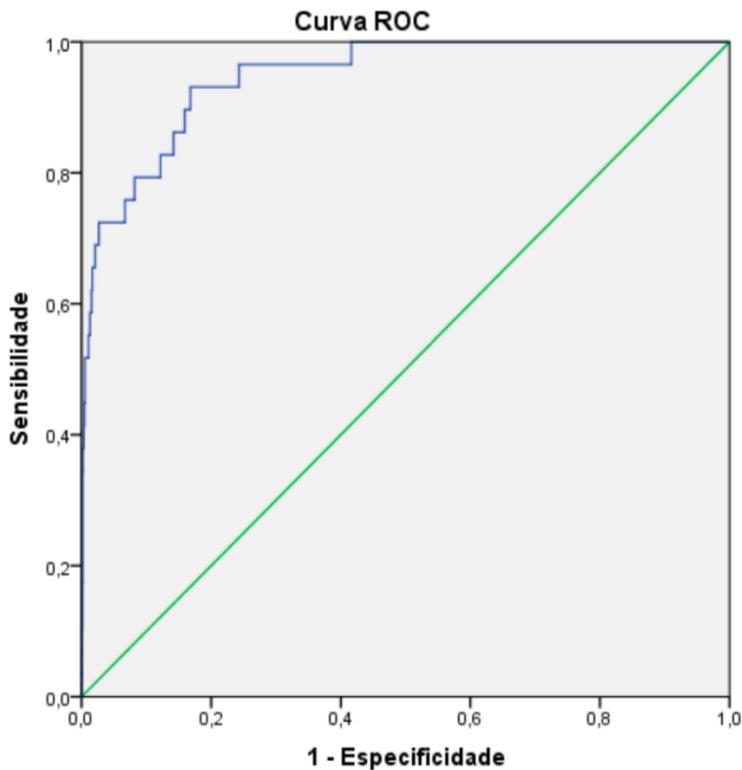
**Tabela 5** - Sensibilidade, especificidade, VPP, VPN, RVP, RVN, DOR para o algoritmo de RNC e para as alterações maiores ao ECG. ASC-ROC para o algoritmo de RNC

Parâmetro	Algoritmo de RNC	Alterações maiores ao ECG
Sensibilidade	0,690	0,172
Especificidade	0,976	0,837
Valor preditivo positivo	0,244	0,012
Valor preditivo negativo	0,996	0,989
Razão de verossimilhança positiva	27,6	1,09
Razão de verossimilhança negativa	0,32	0,99
Diagnostic odds ratio	88,74	1,07
ASC-ROC	0,947 (IC 95% 0,913 – 0,981)	NA

Fonte: Elaboração do autor. NA = não se aplica. RNC: Rede neural convolucional; ASC-ROC: Área Sob a Curva - Receiver operating characteristic

**FIGURAS****Figura 1**

Fonte: Elaboração do autor.

**Figura 2**

Fonte: *Software SPSS*, versão 21

## MATERIAL SUPLEMENTAR

**Tabela Suplementar:** Características clínicas dos participantes do ELSA-Brasil versus participantes do estudo

	ELSA-Brasil	Participantes do estudo
Número	15105	2567
Idade (anos), mediana e IQ (25-75)	51 (45 – 58)	52 (56 – 66)
Pressão arterial sistólica, mediana e IQ (25-75)	119 (109 – 130,5)	123,50 (113,00 – 136,50)
HDL colesterol (mg/dL), mediana e IQ (25-75)	51,08 (43,82 – 61,07)	52,90 (44,73 – 62,89)
Colesterol total (mg/dL), mediana e IQ (25-75)	198,1 (172,91 – 224,25)	198,10 (172,91 – 226,19)
Glicemia de jejum (mg/dL), mediana e IQ (25-75)	105 (98 – 114)	107,00 (100,00 – 117,00)
Dislipidemia (%)	49,5	55,7
Hipertensão arterial sistêmica (%)	35,8	49,5
Tabagismo (%)	13,1	10,0
Diabetes Melítus (%)	16,1	21,9
Doença Arterial Periférica (%)	4,1	5,6
Acidente Vascular Cerebral (%)	1,3	1,9
Doença Cardiovascular auto-referida (%)	6,9	10,9

Fonte: Elaboração do autor.

## REFERÊNCIAS

- Oliveira GMM de, Brant LCC, Polanczyk CA, Malta DC, Biolo A, Nascimento BR, *et al.* Estatística Cardiovascular – Brasil 2021. *Arq Bras Cardiol.* 2022 Jan 19;118(1):115–373.
- 2022 AHA/ACC/HFSA Guideline for the Management of Heart Failure: A Report of the American College of Cardiology/American Heart Association Joint Committee on Clinical Practice Guidelines [Internet]. [cited 2023 Jan 16]. Available from: <https://www.ahajournals.org/doi/epdf/10.1161/CIR.0000000000001063>
- Libby P, Bonow R, Mann D, Tomaselli G, Bhatt D, Solomon S, editors. Braunwald’s heart disease: a textbook of cardiovascular medicine. 12th ed. Philadelphia: Elsevier; 2021.
- McDonagh TA, Metra M, Adamo M, Gardner RS, Baumbach A, Böhm M, *et al.* 2021 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure. *Eur Heart J.* 2021 Sep 21;42(36):3599–726.
- Cestari VRF, Garces TS, Sousa GJB, Maranhão TA, Souza JD, Pereira MLD, *et al.* Distribuição Espacial de Mortalidade por Insuficiência Cardíaca no Brasil, 1996-2017. *Arq Bras Cardiol* [Internet]. 2021 Nov 17 [cited 2022 Oct 25]; Available from:
- CAMPBELL, S.M. *et al.* Diagnostic triage and the role of natriuretic peptide testing and echocardiography for suspected heart failure: an appropriateness ratings evaluation by UK

- GPs. **Br J Gen Pract.**, v. 61(588):e427-35, jul 2011. Disponível em: <https://doi.org/10.3399/bjgp11x583218>. Acesso em: 25 out. 2022.
7. Rohde LEP, Montera MW, Bocchi EA, Clausell NO, Albuquerque DC de, Rassi S, *et al.* Diretriz Brasileira de Insuficiência Cardíaca Crônica e Aguda. *Arq Bras Cardiol* [Internet]. 2018 [cited 2022 Oct 25]; Available from: [https://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0066-782X2018001500436](https://www.scielo.br/scielo.php?script=sci_arttext&pid=S0066-782X2018001500436)
  8. Haug CJ, Drazen JM. Artificial Intelligence and Machine Learning in Clinical Medicine, 2023. Drazen JM, Kohane IS, Leong TY, editors. *N Engl J Med.* 2023 Mar 30;388(13):1201–8.
  9. Stuart J. Russell, Peter Norvig. *Inteligência Artificial - Uma Abordagem Moderna.* 4th ed. GEN - LTC; 2022.
  10. Isaías Lima, Carlos A.M. Pinheiro, Flávia A. Oliveira Santos. *Inteligência artificial.* 1st ed. GEN - LTC; 2014. 177 p.
  11. Friedrich S, Groß S, König IR, Engelhardt S, Bahls M, Heinz J, *et al.* Applications of artificial intelligence/machine learning approaches in cardiovascular medicine: a systematic review with recommendations. *Eur Heart J - Digit Health.* 2021 Sep 30;2(3):424–36.
  12. Lima EM, Ribeiro AH, Paixão GMM, Ribeiro MH, Pinto-Filho MM, Gomes PR, *et al.* Deep neural network-estimated electrocardiographic age as a mortality predictor. *Nat Commun.* 2021 Aug 25;12(1):5117.
  13. Siontis KC, Noseworthy PA, Attia ZI, Friedman PA. Artificial intelligence-enhanced electrocardiography in cardiovascular disease management. *Nat Rev Cardiol.* 2021 Jul;18(7):465–78.
  14. Ranka S, Reddy M, Noheria A. Artificial intelligence in cardiovascular medicine. *Curr Opin Cardiol.* 2021 Jan;36(1):26–35.
  15. Olsen CR, Mentz RJ, Anstrom KJ, Page D, Patel PA. Clinical applications of machine learning in the diagnosis, classification, and prediction of heart failure. *Am Heart J.* 2020 Nov;229:1–17.
  16. Choi DJ, Park JJ, Ali T, Lee S. Artificial intelligence for the diagnosis of heart failure. *Npj Digit Med.* 2020 Apr 8;3(1):54.
  17. Yasmin F, Shah SMI, Naeem A, Shujaiddin SM, Jabeen A, Kazmi S, *et al.* Artificial intelligence in the diagnosis and detection of heart failure: the past, present, and future. *Rev Cardiovasc Med.* 2021;22(4):1095.

18. Attia ZI, Kapa S, Lopez-Jimenez F, McKie PM, Ladewig DJ, Satam G, *et al.* Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram. *Nat Med.* 2019 Jan;25(1):70–4.
19. Cho J, Lee B, Kwon JM, Lee Y, Park H, Oh BH, *et al.* Artificial Intelligence Algorithm for Screening Heart Failure with Reduced Ejection Fraction Using Electrocardiography. *ASAIO J.* 2021 Mar;67(3):314–21.
20. Akbilgic O, Butler L, Karabayir I, Chang PP, Kitzman DW, Alonso A, *et al.* ECG-AI: electrocardiographic artificial intelligence model for prediction of heart failure. *Eur Heart J - Digit Health.* 2021 Dec 29;2(4):626–34.
21. Chen HY, Lin CS, Fang WH, Lou YS, Cheng CC, Lee CC, *et al.* Artificial Intelligence-Enabled Electrocardiography Predicts Left Ventricular Dysfunction and Future Cardiovascular Outcomes: A Retrospective Analysis. *J Pers Med.* 2022 Mar 13;12(3):455.
22. Grün D, Rudolph F, Gumpfer N, Hannig J, Elsner LK, von Jeinsen B, *et al.* Identifying Heart Failure in ECG Data With Artificial Intelligence—A Meta-Analysis. *Front Digit Health.* 2021 Feb 25;2:584555.
23. LI XM, GAO XY, Tse G, HONG SD, CHEN KY, LI GP, *et al.* Electrocardiogram-based artificial intelligence for the diagnosis of heart failure: a systematic review and meta-analysis. *J Geriatr Cardiol.* 2022; 19:11.
24. Sangha V, Nargesi AA, Dhingra LS, Khunte A, Mortazavi BJ, Ribeiro AH, *et al.* Detection of Left Ventricular Systolic Dysfunction From Electrocardiographic Images. *Circulation.* 2023 Jul 25; CIRCULATIONAHA.122.062646.
25. Cormen TT. Algoritmos - Teoria e Prática. 3a edição. GEN LTC; 2012.
26. Bhargava AY. Entendendo Algoritmos: Um Guia Ilustrado Para Programadores e Outros Curiosos. 1a edição. Novatec Editora; 2017.
27. Mill JG, Pinto K, Griep RH, Goulart A, Foppa M, Lotufo PA, *et al.* Afericoes e exames clinicos realizados nos participantes do ELSA-Brasil. *Rev Saúde Pública.* 2013 Jun;47(suppl 2):54–62.

## 7 CONSIDERAÇÕES FINAIS

A IC FER é uma condição clínica grave com alta mortalidade e morbidade global. O tratamento farmacológico desempenha um papel crucial na melhoria da qualidade de vida dos pacientes e na redução dos custos para o sistema de saúde. O diagnóstico da IC FER é tradicionalmente realizado por meio de ecocardiografia (ECO), que avalia a função cardíaca e estima a fração de ejeção ventricular esquerda (FEVE). No entanto, o acesso à ECO ainda é limitado a centros médicos de maior porte devido aos custos associados ao equipamento e à formação médica necessária para a sua realização. Portanto, é de fundamental importância que o diagnóstico desta doença seja feito de maneira precoce.

Na prática clínica, os médicos usam parâmetros como as AME como indicadores de suspeita de IC FER, levando à realização da ECO para confirmação do diagnóstico. No entanto, as AME têm uma sensibilidade limitada na predição da disfunção sistólica ventricular esquerda (DSVE).

Neste contexto, a IA surge como uma alternativa promissora. O algoritmo de IA utilizado neste trabalho demonstrou desempenho superior em relação às AME na detecção de DSVE, de acordo com os testes de acurácia. O algoritmo é capaz de detectar outros padrões de anormalidades ao ECG, diferentes das que utilizamos habitualmente.

O algoritmo de IA é altamente específico e projetado para avaliar ECGs, aproveitando hardware robusto e uma grande quantidade de dados (Big Data) para análises mais precisas. Em comparação, médicos têm exposição limitada a ECGs durante seu treinamento, e parte das informações visualizadas se perde devido à limitação da memória humana.

A prevalência de IC na população estudada foi semelhante à média nacional, mostrando robustez dos resultados obtidos. Além disso, o ECG é um exame de baixo custo e amplamente disponível, possibilitando que essa tecnologia seja amplamente utilizada.

A IA aplicada à análise de ECGs promete ter um impacto positivo no cenário da IC no Brasil, com suas numerosas Unidades Básicas de Saúde e Unidades de Pronto Atendimento. A transmissão de ECGs para pontos de Telessaúde, onde o algoritmo de IA pode ser usado como um programa de triagem para IC, oferece a oportunidade de identificar precocemente pacientes com a condição, encaminhando-os para avaliação cardiológica prioritária e reduzindo a mortalidade e morbidade associadas às doenças cardiovasculares.

Conclui-se que a IA aplicada à análise de ECGs pode ser uma ferramenta valiosa no diagnóstico precoce da IC FER, melhorando os resultados clínicos e reduzindo os custos associados a essa condição de saúde.

## 8 PERSPECTIVAS

Em 1963 foi publicado no PubMed o primeiro artigo que trazia no título o termo ‘inteligência artificial’. Esse artigo tinha como objetivo entender melhor o funcionamento do cérebro a partir de um dispositivo neuronal artificial (49). Nesse mesmo ano, outro artigo avaliava o uso da IA na leitura do ECG (50). Apesar de terem decorridos 60 anos destas duas publicações, foi somente nos últimos anos que esse tema se tornou mais presente, quase palpável, no dia a dia. O número de publicações no PubMed sobre IA reflete isso: observa-se um ponto de inflexão no número de artigos entre 2017 e 2018.

O presente trabalho pretende ser mais uma contribuição para esse campo que tem se mostrado muito promissor na área da saúde, especialmente na cardiologia, área médica cujas doenças são a principal causa de morte no mundo.

Os estudos até aqui avaliaram o uso da IA aplicada ao ECG no contexto ambulatorial. Faz-se necessário, então, que essa tecnologia seja avaliada no âmbito das emergências médicas, cenário no qual as DCV também são muito prevalentes (51-53).

Esperamos que, brevemente, a tecnologia analisada nesse estudo esteja difundida, melhorando o diagnóstico de IC e reduzindo os impactos desta doença na sociedade.

Após defesa desta dissertação, submeteremos um artigo com nossos achados à publicação em um periódico científico.

## REFERÊNCIAS

- <sup>1</sup> INSTITUTE FOR HEALTH METRICS AND EVALUATION (IHME). **GBD Compare**. Disponível em: <http://vizhub.healthdata.org/gbd-compare>. Acesso em: 16 jun. 2023.
- <sup>2</sup> OLIVEIRA, G. M. M. de. *et al.* Estatística Cardiovascular – Brasil 2021. **Arq Bras Cardiol.**, v 188, n. 1, p. 115-373, jan. 2022. Disponível em: <https://doi.org/10.36660/abc.20211012>. Acesso em: 16 jan. 2023.
- <sup>3</sup> HEIDENREICH, P. A. *et al.* 2022 AHA/ACC/HFSA Guideline for the Management of Heart Failure: A Report of the American College of Cardiology/American Heart Association Joint Committee on Clinical Practice Guidelines. **AHA Journals - Circulation**, v. 145, n. 18, e895–e1032, maio 2022. Disponível em: <https://www.ahajournals.org/doi/epdf/10.1161/CIR.0000000000001063>. Acesso em: 16 jan. 2023.
- <sup>4</sup> LIBBY, P. *et al.* (ed.). **Braunwald’s heart disease: a textbook of cardiovascular medicine**. 12. ed. Philadelphia: Elsevier, 2021.
- <sup>5</sup> ROHDE, L.E.P. *et al.* Diretriz brasileira de insuficiência cardíaca crônica e aguda. **Arq Bras Cardiol**, v. 111, n.3, p. 436-539, set. 2018. Disponível em: <https://doi.org/10.5935/abc.20180190>. Acesso em: 25 out. 2022.
- <sup>6</sup> MCDONAGH, T.A. *et al.* 2021 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure. **Eur Heart J.**, v. 42, n. 36, p. 3599–726, set. 2021. Disponível em: doi: 10.1093/eurheartj/ehab368. Acesso em: 25 out. 2022.
- <sup>7</sup> ALMEIDA, D.R. *et al.* The Medical Burden of Heart Failure: A Comparative Delineation with Cancer in Brazil. **Int. J. Cardiovasc. Sci.**, v. 35, n. 4, p. 514-520, Mar. 2022. Disponível em: <https://ijcardiol.org/article/the-medical-burden-of-heart-failure-a-comparative-delineation-with-cancer-in-brazil/>. Acesso em: 17 jun. 2023.
- <sup>8</sup> KALIL FILHO, R.; FUSTER, V. **Medicina cardiovascular**. Rio de Janeiro: Atheneu, 2016.
- <sup>9</sup> CESTARI, V. R. F. *et al.* Distribuição Espacial de Mortalidade por Insuficiência Cardíaca no Brasil, 1996-2017. **Arq Bras Cardiol**, v. 118, n. 1, p. 41–51, jan. 2022. Disponível em: <https://abccardiol.org/article/distribuicao-espacial-de-mortalidade-por-insuficiencia-cardiaca-no-brasil-1996-2017/>. Acesso em: 25 out. 2022.
- <sup>10</sup> SOUZA, S.C. *et al.* Número de internações hospitalares, custos hospitalares, média de permanência e mortalidade por insuficiência cardíaca nas regiões brasileiras, no ano de 2017. *Rev Ciênc Médicas E Biológicas*, v.17, n. 3, p. 376-380, nov. 2018. Disponível em: <https://doi.org/10.9771/cmbio.v17i3.28626>. Acesso em: 25 out. 2022.
- <sup>11</sup> YANCY, C. W. *et al.* 2013 ACCF/AHA Guideline for the Management of Heart Failure: Executive Summary. **AHA Journals - Circulation**, v. 126, n. 16, p. 1810-1852, out. 2013. Disponível em: <https://www.ahajournals.org/doi/epdf/10.1161/CIR.0b013e31829e8807>. Acesso em: 16 jan. 2023.

- <sup>12</sup> DAVIE, A.P. *et al.* Value of the electrocardiogram in identifying heart failure due to left ventricular systolic dysfunction. **BMJ**, v. 312, 7025, p. 222, jan. 1996. Disponível em: <https://doi.org/10.1136/bmj.312.7025.222>. Acesso em: 16 jan. 2023.
- <sup>13</sup> MOSTERD, A. *et al.* Usefulness of Echocardiography in Detecting Left Ventricular Dysfunction in Population-Based Studies (The Rotterdam Study). **Am J Cardiol**, v. 19, n.1, p. 103-104, jan. 1997. Disponível em: [https://doi.org/10.1016/s0002-9149\(96\)00691-1](https://doi.org/10.1016/s0002-9149(96)00691-1). Acesso em: 17 jan. 2023.
- <sup>14</sup> GOUDIE, B. M. *et al.* Screening for left ventricular systolic dysfunction using GP-reported ECGs. **Br J Gen Pract J R Coll Gen Pract**, v. 57, n. 536, p.191-195, mar. 2007. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2042566/>. Acesso em: 17 jan. 2023.
- <sup>15</sup> MADHOK, V. *et al.* The accuracy of symptoms, signs and diagnostic tests in the diagnosis of left ventricular dysfunction in primary care: a diagnostic accuracy systematic review. **BMC Fam Pract.**, v. 9, n.1, dez. 2008. Disponível em: <https://doi.org/10.1186/1471-2296-9-56>. Acesso em: 17 jan. 2023.
- <sup>16</sup> MANT, J. *et al.* Systematic review and individual patient data meta-analysis of diagnosis of heart failure, with modelling of implications of different diagnostic strategies in primary care. **Health Technol Assess**, v.13, n. 32, jul. 2009. Disponível em: <https://www.journalslibrary.nihr.ac.uk/hta/hta13320/>. Acesso em: 22 jun. 2023.
- <sup>17</sup> MINSKY, M. **A sociedade da mente**. Rio de Janeiro: Francisco Alves, 1989.
- <sup>18</sup> LIMA, I.; PINHEIRO, C.A.M.; SANTOS, F.A.O. **Inteligência artificial**. Rio de Janeiro: GEN LTC, 2014.
- <sup>19</sup> MEDEIROS, L. F. M. **Inteligência artificial aplicada: uma abordagem introdutória**. Curitiba: Intersaberes, 2018.
- <sup>20</sup> RUSSELL, S. J.; NORVIG, P. **Inteligência artificial: uma abordagem moderna**. Rio de Janeiro: GEN - LTC, 2022.
- <sup>21</sup> OPENAI. **ChatGPT**. Disponível em: <https://chat.openai.com/>. Acesso em: 17 jun. 2023.
- <sup>22</sup> SOUZA FILHO, E. M. *et al.* Inteligência artificial em cardiologia: conceitos, ferramentas e desafios – “quem corre é o cavalo, você precisa ser o jóquei”: inteligência artificial em cardiologia. **Arq Bras Cardiol**, v.114, n. 4, p. 718–725, abr. 2020. Disponível em: <https://doi.org/10.36660/abc.20180431>. Acesso em: 3 jun. 2023.
- <sup>23</sup> FRANCO, C. R. **Inteligência artificial**. Londrina: Editoria e Distribuidora Educacional S.A., 2014.
- <sup>24</sup> LUGER, G. **Inteligência Artificial**. 6. ed. São Paulo: Pearson Education do Brasil, 2014.
- <sup>25</sup> NEVES, B. C. Inteligência artificial e computação cognitiva em unidades de informação: conceitos e experiências. **Logeion Filos Informação**, v. 7, n. 1, p.186-205, set. 2020. Disponível em: <https://doi.org/10.21728/logcion.2020v7n1.p186-205>. Acesso em: 25 out. 2022.

- <sup>26</sup> CORMEN, T.T. **Algoritmos: teoria e prática**. 3. ed. Rio de Janeiro: GEN LTC, 2012.
- <sup>27</sup> BHARGAVA, A. Y. **Entendendo algoritmos: um guia ilustrado para programadores e outros curiosos**. São Paulo: Novatec Editora, 2017.
- <sup>28</sup> BAKER, A. *et al.* A comparison of artificial intelligence and human doctors for the purpose of triage and diagnosis. **Front Artif Intell**, v. 3: 543405, nov. 2020. Disponível em: <https://doi.org/10.3389/frai.2020.543405>. Acesso em: 25 out. 2022.
- <sup>29</sup> SHEN, J. *et al.* Artificial intelligence versus clinicians in disease diagnosis: systematic review. **JMIR Med Inform**. v.7, n. 3, e10010, ago. 2019. Disponível em: <https://doi.org/10.2196/10010>. Acesso em: 25 out. 2022.
- <sup>30</sup> HAUG, C.J.; DRAZEN, J.M. Artificial intelligence and machine learning in clinical medicine, 2023. **N Engl J Med.**, v. 388, n. 13, p. 1201-1208, mar. 2023. Disponível em: <https://doi.org/10.1056/nejmra2302038>. Acesso em: 17 jun. 2023.
- <sup>31</sup> LIU, P. *et al.* Application of artificial intelligence in medicine: an overview. **Curr Med Sci.**, v. 41, n. 6, p. 1105-1115, dez. 2021. Disponível em: <https://doi.org/10.1007%2Fs11596-021-2474-3>. Acesso em: 25 out. 2022.
- <sup>32</sup> SIONTIS, K.C. *et al.* Artificial intelligence-enhanced electrocardiography in cardiovascular disease management. **Nat Rev Cardiol**. v.18, n.7, p.465–478, jul. 2021. Disponível em: <https://doi.org/10.1038/s41569-020-00503-2>. Acesso em: 3 jun. 2023.
- <sup>33</sup> FRIEDRICH, S. *et al.* Applications of artificial intelligence/machine learning approaches in cardiovascular medicine: a systematic review with recommendations. **Eur Heart J - Digit Health**. v. 2, n.3, p.424–436, set. 2021. Disponível em: <https://doi.org/10.1093/ehjdh/ztab054>. Acesso em: 25 out. 2022.
- <sup>34</sup> LIMA, E.M. *et al.* Deep neural network-estimated electrocardiographic age as a mortality predictor. **Nat Commun.**, v. 12, n.1:5117, ago. 2021. Disponível em: <https://doi.org/10.1038/s41467-021-25351-7>. Acesso em: 25 out. 2022.
- <sup>35</sup> OLSEN, C.R. *et al.* Clinical applications of machine learning in the diagnosis, classification, and prediction of heart failure. **Am Heart J.**, v. 229, p. 1–17, nov. 2020. Disponível em: <https://doi.org/10.1016/j.ahj.2020.07.009>. Acesso em: 25 out. 2022.
- <sup>36</sup> CHOI, D.J. *et al.* Artificial intelligence for the diagnosis of heart failure. **Npj Digit Med.**, v. 3, art. n. 54, abr. 2020. Disponível em: <https://doi.org/10.1038/s41746-020-0261-3>. Acesso em: 25 out. 2022.
- <sup>37</sup> YASMIN, F. *et al.* Artificial intelligence in the diagnosis and detection of heart failure: the past, present, and future. **Rev Cardiovasc Med**.v. 22, n.4, p. 1095-1113, dez. 2021. Disponível em: <https://doi.org/10.31083/j.rcm2204121>. Acesso em: 25 out. 2022.
- <sup>38</sup> AVERBUCH, T. *et al.* Applications of artificial intelligence and machine learning in heart failure. **Eur Heart J - Digit Health.**, v. 3, n.2, p. 311–22, jun. 2022. Disponível em: <https://doi.org/10.1093/ehjdh/ztac025>. Acesso em: 25 out. 2022.

- <sup>39</sup> RANKA, S.; REDDY, M.; NOHERIA, A. Artificial intelligence in cardiovascular medicine. **Curr Opin Cardiol.**, v. 36, n.1, p. 26–35, jan. 2021. Disponível em: <https://doi.org/10.1097/hco.0000000000000812>. Acesso em: 25 out. 2022.
- <sup>40</sup> ATTIA, Z. I. *et al.* Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram. **Nat Med.**, v. 25, n.1, p.70–74, jan. 2019. Disponível em: <https://doi.org/10.1038/s41591-018-0240-2>. Acesso em: 25 out. 2022.
- <sup>41</sup> BRITO, B. O. F. *et al.* Left ventricular systolic dysfunction predicted by artificial intelligence using the electrocardiogram in Chagas disease patients—The SaMi-Trop cohort. **PLoS Negl Trop Dis.**, v. 15, n. 12:e0009974, dez. 2021. Disponível em: <https://doi.org/10.1371/journal.pntd.0009974>. Acesso em: 25 out. 2022.
- <sup>42</sup> CHO, J. *et al.* Artificial intelligence algorithm for screening heart failure with reduced ejection fraction using electrocardiography. **ASAIO J.**, v. 67, n. 3, p.314–321, mar. 2021. <https://doi.org/10.1097/mat.0000000000001218>. Acesso em: 25 out. 2022.
- <sup>43</sup> AKBILGIC, O. *et al.* ECG-AI: electrocardiographic artificial intelligence model for prediction of heart failure. **Eur Heart J - Digit Health**, v. 2, n.4, p. 626–634, out. 2021. Disponível em: <https://doi.org/10.1093/ehjdh/ztab080>. Acesso em: 25 out. 2022.
- <sup>44</sup> CHEN, H.Y. *et al.* Artificial intelligence-enabled electrocardiography predicts left ventricular dysfunction and future cardiovascular outcomes: a retrospective analysis. **J Pers Med.**, v. 12, n. 3:455, mar. 2022. Disponível em: <https://doi.org/10.3390/jpm12030455>. Acesso em: 25 out. 2022.
- <sup>45</sup> GRÜN, D. *et al.* Identifying heart failure in ECG data with artificial intelligence—a meta-analysis. **Front Digit Health.**, v. 2:584555, fev. 2021. Disponível em: <https://doi.org/10.3389/fdgth.2020.584555>. Acesso em: 25 out. 2022.
- <sup>46</sup> LI, X.M. *et al.* Electrocardiogram-based artificial intelligence for the diagnosis of heart failure: a systematic review and meta-analysis. **J Geriatr Cardiol.**, v. 19, 11, dez. 2022. Disponível em: <https://doi.org/10.11909/j.issn.1671-5411.2022.12.002>. Acesso em: 3 jun. 2023.
- <sup>47</sup> SANGHA, V. *et al.* Detection of left ventricular systolic dysfunction from electrocardiographic images. **AHA Journals - Circulation**, v. 148, p. 765–777, jul. 2023. Disponível em: <https://doi.org/10.1161/CIRCULATIONAHA.122.062646>. Acesso em: 22 out. 2023.
- <sup>48</sup> MILL, J.G. *et al.* Aferições e exames clínicos realizados nos participantes do ELSA-Brasil. **Rev Saúde Pública**, v. 47, suppl. 2, p. 54–62, jun. 2013. Disponível em: <https://doi.org/10.1590/S0034-8910.2013047003851>. Acesso em: 25 out. 2022.
- <sup>49</sup> MARON, M. E. **Artificial intelligence and brain mechanisms**. RAND Corporation, RM-3522-PR, 1963. Disponível em: [https://www.rand.org/pubs/research\\_memoranda/RM3522.html](https://www.rand.org/pubs/research_memoranda/RM3522.html). Acesso em: 25 out. 2022.

<sup>50</sup> OKAJIMA, M. *et al.* Computer pattern recognition techniques: some results with real electrocardiographic data. **IEEE Trans Biomed Eng.**, v.10, n.3, p.106–114, jul. 1963. Disponível em: <https://doi.org/10.1109/tbmel.1963.4322808>. Acesso em: 25 out. 2022.

<sup>51</sup> HEHN, R.; BUENO, A.L.M. Perfil epidemiológico dos atendimentos de um pronto atendimento privado do sul do Brasil. **Rev Enferm UFSM**, v. 10:e58, jul. 2020. Disponível em: <https://periodicos.ufsm.br/reufsm/article/view/37989/pdf>. Acesso em: 25 out. 2022.

<sup>52</sup> HORA, R.S.D. et al. Caracterização do atendimento do Serviço de Atendimento Móvel de Urgência (SAMU) às emergências clínicas. **Reme Rev Min Enferm.**, v. 23, e-1256, 2019. Disponível em: <http://www.revenf.bvs.br/pdf/reme/v23/1415-2762-reme-23-e1256.pdf>. Acesso em: 25 out. 2022.

<sup>53</sup> CARRET, M.L.V. *et al.* Características da demanda do serviço de saúde de emergência no Sul do Brasil. **Ciênc Saúde Coletiva**, v. 16, suppl 1, p.1069–79, 2011. Disponível em: <https://doi.org/10.1590/S1413-81232011000700039>. Acesso em: 25 out. 2022.