

Uso da Inteligência Artificial Aplicada ao Eletrocardiograma para Diagnóstico de Disfunção Sistólica Ventricular Esquerda

Use of Artificial Intelligence Applied to Electrocardiogram for Diagnosis of Left Ventricular Systolic Dysfunction

Wilton Batista de Santana Júnior,¹ Marcelo M. Pinto-Filho,¹ Sandhi Maria Barreto,¹ Murilo Foppa,² Luana Giatti,¹ Rohan Khera,³ Antonio Luiz Pinho Ribeiro¹

Universidade Federal de Minas Gerais (UFMG),¹ Belo Horizonte, MG – Brasil

Hospital de Clínicas de Porto Alegre,² Porto Alegre, RS – Brasil

Yale University,³ New Haven – EUA

Resumo

Fundamento: A insuficiência cardíaca é uma doença associada a importante morbimortalidade. O eletrocardiograma (ECG), um dos exames utilizados na avaliação da IC, é 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 Ventricular Esquerda; Eletrocardiografia.

Abstract

Background: Heart failure (HF) is a disease associated with an important type of morbidity and mortality. The electrocardiogram (ECG), one of the tests used to evaluate HF, is low-cost and widely available.

Objective: To evaluate the performance of an artificial intelligence (AI) algorithm applied to ECG to detect HF and compare it with the predictive power of major electrocardiographic alterations (MEA).

Methods: This work is a diagnostic accuracy cross-sectional study. All participants were from the Longitudinal Study of Adult Health (Estudo Longitudinal da Saúde do Adulto - ELSA-Brasil) and presented a valid ECG and echocardiogram (ECHO). The algorithm estimated probability values for left ventricular systolic dysfunction (LVSD). The assessed endpoint was left ventricular ejection fraction (LVEF) <40% in the ECHO. Sensitivity, specificity, positive predictive value (PPV), negative predictive value (NPV), positive likelihood ratio (LR+), negative likelihood ratio (LR-), and diagnostic odds ratio (DOR) were determined for both the algorithm and the MEA. The area under the ROC curve (AUC-ROC) for the algorithm was calculated.

Results: In the analytical sample of 2,567 individuals, the prevalence of LVEF <40% was 1.13% (29 individuals). The values obtained for sensitivity, specificity, PPV, NPV, LR+, LR-, and DOR for the algorithm were 0.690, 0.976, 0.244, 0.996, 27.6, 0.32, and 88.74, respectively. For the MEA, the values were 0.172, 0.837, 0.012, 0.989, 1.09, 0.990, and 1.07, respectively. The AUC-ROC of the algorithm to predict the LVEF <40% was 0.947 (95% CI: 0.913 – 0.981).

Correspondência: Antonio Luiz Pinho Ribeiro •

Centro de Telessaúde - Hospital das Clínicas - UFMG - Av. Professor Alfredo Balena, 110 - 1º andar - Ala Sul - Sala 107. CEP 30130-100, Belo Horizonte, MG - Brasil

E-mail: alpr1963br@gmail.com

Artigo recebido em 05/11/2024, revisado em 27/12/2024, aceito em 05/02/2025

Editor responsável pela revisão: Gláucia Maria Moraes de Oliveira

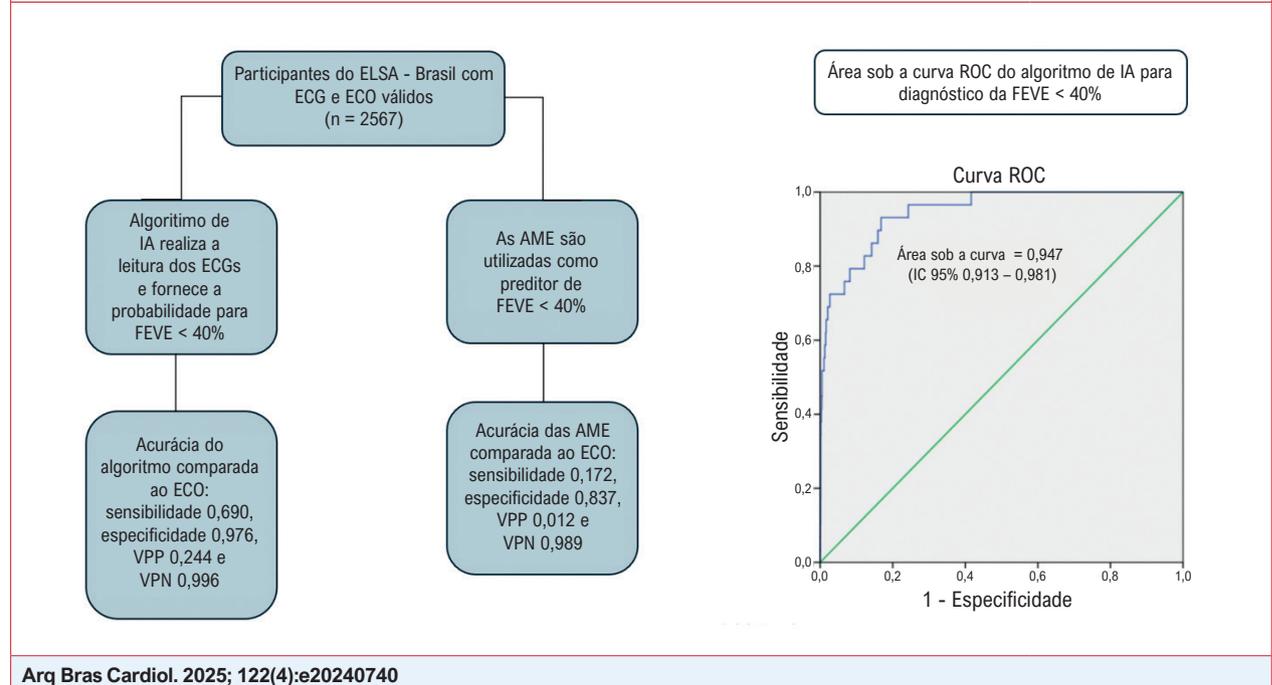
DOI: <https://doi.org/10.36660/abc.20240740>

Conclusion: The AI algorithm performed well in detecting LVSD and can be used as a screening tool for LVSD.

Keywords: Artificial Intelligence; Heart Failure; Left Ventricular Dysfunction; Electrocardiography.

Full texts in English - <https://abccardiol.org/en/>

Figura Central: Uso da Inteligência Artificial Aplicada ao Eletrocardiograma para Diagnóstico de Disfunção Sistólica Ventricular Esquerda



Dados de acurácia de um algoritmo de IA e das AME para detecção da DSVE (FEVE < 40%). IA: inteligência artificial; AME: alterações maiores ao eletrocardiograma; DSVE: disfunção sistólica do ventrículo esquerdo; FEVE: fração de ejeção do ventrículo esquerdo; ELSA: Estudo Longitudinal da Saúde do Adulto; ECG: eletrocardiograma; ROC: Receiver Operating Characteristic; VPP: valor preditivo positivo; VPN: valor preditivo negativo.

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 tendo alta taxa de mortalidade intrahospitalar.^{1,5-7} O ecocardiograma (ECO) é uma 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 tem 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 sua disponibilidade 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, tem acurácia limitada^{3,4,7} necessitando de aprimoramentos para prestar para 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 anos¹¹ 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 tenham 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.

Uma Rede Neural Convolutiva (RNC ou CNN – *Convolutional Neural Network*, em inglês) nada mais é que um algoritmo de aprendizado profundo, ou *deep learning*. Esse tipo de rede capta o sinal de entrada, que pode ser uma imagem, e atribui pesos a vários dos seus aspectos. Dessa maneira, a RNC consegue diferenciar tais aspectos, o que é fundamental para a composição do sinal de saída. A arquitetura de tais redes é inspirada na do cérebro humano, mais especificamente do córtex visual. No caso da análise de ECG pode haver limitações como qualidade do traçado devido ao posicionamento de eletrodos e interferências, entre outros. Isso pode afetar a acurácia do modelo e sua utilização nas mais diversas condições de obtenção de um ECG.

Métodos

Desenho do estudo e participantes

Trata-se de um estudo transversal de acurácia diagnóstica. Os participantes são do Estudo Longitudinal do Adulto (ELSA-Brasil).²⁷ Foram incluídos todos os indivíduos que tivessem ECG e ECO válidos, além dos dados de probabilidade de DSVE estimada pelo algoritmo de IA.

Desenvolvimento da Rede Neural Convolutiva

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 a validação externa foi realizada com indivíduos de cinco centros, entre eles o ELSA-Brasil. Foi utilizado um modelo de RNC baseado 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, se optou 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 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, se criou 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, priorizando 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 digitalmente ao Centro de Leitura de Ecocardiografia de ELSA. 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.

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. O teste utilizado para avaliar a normalidade dos dados foi o Kolmogorov-Smirnov e o nível de significância adotado foi $p < 0,05$.

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) e foi utilizado o intervalo de confiança de 95%.

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

Considerações éticas

O estudo original de onde parte nossa análise transversal aninhada foi aprovado pelo comitê de ética sob parecer no. 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.

Resultados

Após aplicados os critérios de seleção na amostra total do ELSA-Brasil, dos 15105 indivíduos, 3396 tinham ECO e ECG válidos. Desses, 2567 tinham ECO, ECG e informação de probabilidade de IC pelo algoritmo, havendo perda de 829 indivíduos. Provavelmente, essa perda ocorreu durante a transmissão para o centro onde os ECGs foram lidos pelo algoritmo. As características clínicas desses participantes se encontram na Tabela Suplementar 1. De forma geral, estes participantes apresentaram um perfil de risco cardiovascular mais grave quando comparado à população geral do ELSA-Brasil, mas semelhante ao perfil dos participantes incluídos no estudo. 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 se verifica maior prevalência de dislipidemia, tabagismo, diabetes mellitus, acidente vascular cerebral, e doença cardiovascular autorreferida. A prevalência de FEVE < 40% foi de 1,13%. As características clínicas dos 15105 participantes do ELSA-Brasil estão disponibilizadas na Tabela Suplementar 2.

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 se mostrou superior em relação às AME conforme demonstrado pelos testes de acurácia. 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 tem 88 vezes mais chances de ser identificado pelo teste. Por fim, a ASC-ROC do algoritmo foi de 0,947, mostrando ter boa capacidade de discriminar indivíduos doentes dos não-doentes.

No nosso estudo, a prevalência de DSVE foi de 1,13% e o algoritmo de inteligência artificial (IA) desenvolvido apresentou uma sensibilidade de 69% e especificidade de 97,6%. A baixa prevalência resultou em um VPP pequeno, 24,4%, significando uma proporção muito grande de falsos positivos, e um VPN de 99,6%. Partindo de populações

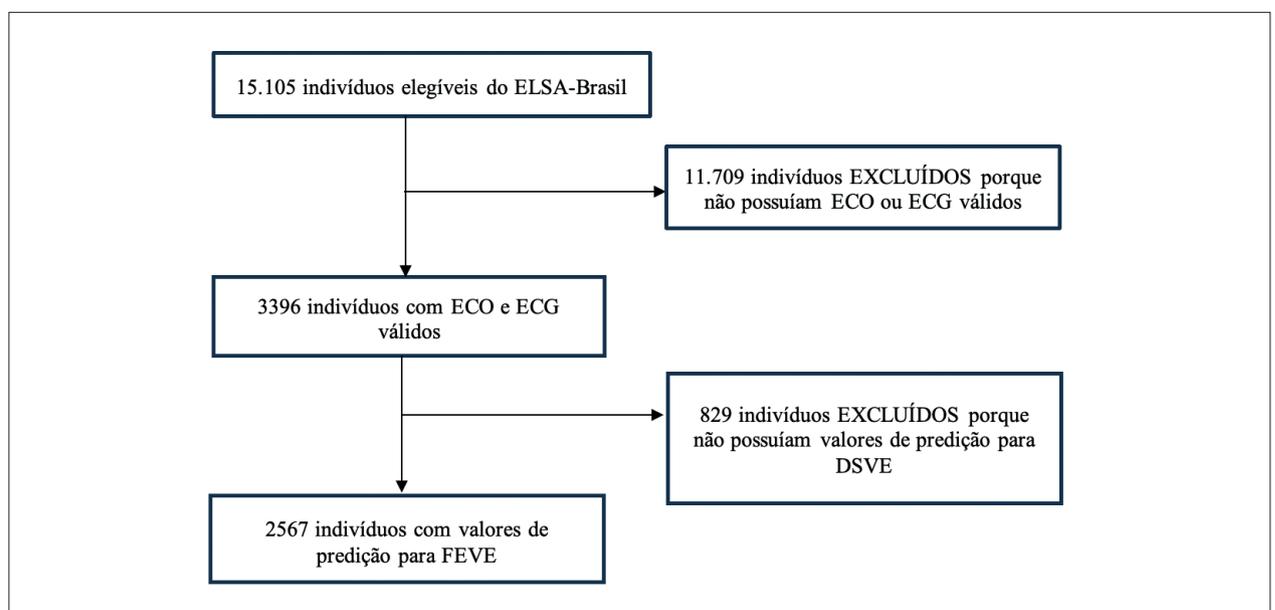


Figura 1 – Fluxograma de seleção dos participantes. ELSA: Estudo Longitudinal da Saúde do Adulto; ECO: ecocardiograma; ECG: eletrocardiograma; DSVE: disfunção sistólica do ventrículo esquerdo; FEVE: fração de ejeção do ventrículo esquerdo.

Tabela 1 – Características clínicas dos participantes do estudo

| | População geral | Homens | Mulheres |
|--|-----------------------------|-----------------------------|-----------------------------|
| 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 |

nas quais a prevalência de DSVE seja maior, por exemplo, em indivíduos sintomáticos ou com fatores de risco, o VPP será maior, resultando em uma maior poder de identificar indivíduos verdadeiramente doentes, ainda que às custas de um VPN menor, mas sem impacto significativo. Por exemplo, uma amostra hipotética na qual a prevalência de DSVE fosse 10% o VPP teria um aumento considerável de 24,4% para 79%, com mudança mínima no VPN (de 99,6% para 96%).

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

| Alteração | Frequência (%) |
|--|----------------|
| 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 |

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

| | FEVE (%) | | |
|---------------------------------|--------------|---------------|------|
| | < 40 (1,13%) | ≥ 40 (98,87%) | |
| Predição do algoritmo de IA (%) | ≥10 | 20 | 62 |
| | <10 | 9 | 2476 |

IA: inteligência artificial; FEVE: fração de ejeção do ventrículo esquerdo.

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., utilizaram 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 têm 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. 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 Unidades de Pronto Atendimento (UPA). Em praticamente todas 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, nosso estudo é um dos primeiros estudos avaliando o uso de IA para diagnóstico de IC em uma população brasileira. Sexto, ele compara a acurácia das AME à da IA no diagnóstico de DSVE. E, por fim, para desenvolvimento do algoritmo é necessária uma fase de treinamento na qual são pareados ECGs e ECOs para que o

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

| | | FEVE (%) | |
|---------------------------|----------|--------------|---------------|
| | | < 40 (1,13%) | ≥ 40 (98,87%) |
| 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 (%) | 69,0 | 0,172 |
| Especificidade (%) | 97,6 | 0,837 |
| Valor preditivo positivo (%) | 24,4 | 0,012 |
| Valor preditivo negativo (%) | 99,6 | 0,989 |
| Razão de verossimilhança positiva | 27,6 | 1,09 |
| Razão de verossimilhança negativa | 0,32 | 0,99 |
| <i>Diagnostic odds ratio</i> | 88,74 | 1,07 |
| ASC-ROC | 0,947 (IC 95% 0,913 – 0,981) | NA |

NA: não se aplica; RNC: rede neural convolucional; ASC-ROC: área Sob a Curva – Receiver operating characteristic.

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. No nosso estudo o intervalo de tempo entre a realização do ECG e do ECO foi curto (semanas), garantindo que os exames avaliassem os indivíduos em condições clínicas muito semelhantes, senão iguais.

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. E, segundo, os exames analisados são de pacientes ambulatoriais, portanto desconhecemos o desempenho do algoritmo no contexto de emergência, sendo necessários estudos nesse sentido.

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.

Como se trata de uma tecnologia nova, mais estudos são necessários para avaliar qual seria a acurácia desse algoritmo na análise de ECGs obtidos em situações de mundo real. Daí a necessidade de estudos prospectivos que validem a aplicação dessa tecnologia em diferentes cenários clínicos, garantindo sua aplicabilidade e impacto na prática médica diária.

Agradecimentos

Agradeço aos participantes do estudo ELSA que têm colaborado de maneira singular para o desenvolvimento das ciências da saúde no Brasil.

Contribuição dos autores

Concepção e desenho da pesquisa, análise estatística e redação do manuscrito: Antônio L. P. Ribeiro, Marcelo M. P. Filho, Wilton Santana; Obtenção de dados, Análise e interpretação dos dados e Revisão crítica do manuscrito: Antônio L. P. Ribeiro, Marcelo M. P. Filho, Wilton Santana, Murilo Foppa, Sandhi M. Barreto, Luana Giatti, Rohan Khera; Obtenção de financiamento: Sandhi M. Barreto, Luana Giatti, Antonio L. P. Ribeiro.

Potencial conflito de interesse

Não há conflito com o presente artigo

Fontes de financiamento

O presente estudo não teve fontes de financiamento externas.

Referências

- Oliveira GMM, Brant LCC, Polanczyk CA, Malta DC, Biolo A, Nascimento BR, et al. Cardiovascular Statistics - Brazil 2021. *Arq Bras Cardiol.* 2022;118(1):115-373. doi: 10.36660/abc.20211012.
- Heidenreich PA, Bozkurt B, Aguilar D, Allen LA, Byun JJ, Colvin MM, 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. *Circulation.* 2022;145(18):895-1032. doi: 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;42(36):3599-726. doi: 10.1093/eurheartj/ehab368.
- Cestari VRF, Garces TS, Sousa GJB, Maranhão TA, Souza JD Neto, Pereira MLD, et al. Distribuição Espacial de Mortalidade por Insuficiência Cardíaca

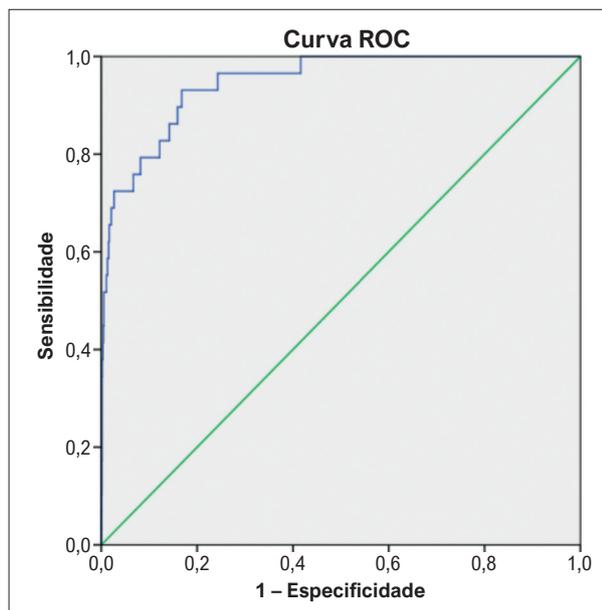


Figura 2 – Área sob a curva ROC do algoritmo de RNC para predição maior que 10% de FEVE < 40%. Fonte: Software SPSS, versão 21.

Vinculação acadêmica

Este artigo é parte de dissertação de mestrado de Wilton Batista de Santana Junior pela Universidade Federal de Minas Gerais.

Aprovação ética e consentimento informado

Este estudo foi aprovado pelo Comitê de Ética em Pesquisa da UFMG – COEP, sob o número de protocolo ETIC 186/06 de 28/06/2006. Todos os procedimentos envolvidos nesse estudo estão de acordo com a Declaração de Helsinki de 1975, atualizada em 2013. O consentimento informado foi obtido de todos os participantes incluídos no estudo.

- no Brasil, 1996-2017. *Arq Bras Cardiol.* 2022;118(1). doi: 10.36660/abc.20201325.
- Campbell SM, Fuat A, Summerton N, Lancaster N, Hobbs FR. 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.* 2011;61(588):e427-35. doi: 10.3399/bjgp11X583218.
- Rohde LEP, Montera MW, Bocchi EA, Clausell NO, Albuquerque DC, Rassi S, et al. Diretriz Brasileira de Insuficiência Cardíaca Crônica e Aguda. *Arq Bras Cardiol.* 2018;111(3):436-539. doi: 10.5935/abc.20180190.
- Haug CJ, Drazen JM. Artificial Intelligence and Machine Learning in Clinical Medicine, 2023. *N Engl J Med.* 2023;388(13):1201-8. doi: 10.1056/NEJMra2302038.
- Russell SJ, Norvig P. Inteligência Artificial - Uma Abordagem Moderna. 4th ed. Rio de Janeiro: Grupo Editorial Nacional; 2022.
- Lima I, Pinheiro CAM, Santos FAO. Inteligência Artificial. Rio de Janeiro: Grupo Editorial Nacional; 2014.

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;2(3):424-36. doi: 10.1093/ehjdh/ztab054.
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;12(1):5117. doi: 10.1038/s41467-021-25351-7.
13. Siontis KC, Noseworthy PA, Attia ZI, Friedman PA. Artificial Intelligence-Enhanced Electrocardiography in Cardiovascular Disease Management. *Nat Rev Cardiol*. 2021;18(7):465-78. doi: 10.1038/s41569-020-00503-2.
14. Ranka S, Reddy M, Noheria A. Artificial Intelligence in Cardiovascular Medicine. *Curr Opin Cardiol*. 2021;36(1):26-35. doi: 10.1097/HCO.0000000000000812.
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;229:1-17. doi: 10.1016/j.ahj.2020.07.009.
16. Choi DJ, Park JJ, Ali T, Lee S. Artificial Intelligence for the Diagnosis of Heart Failure. *NPJ Digit Med*. 2020;3:54. doi: 10.1038/s41746-020-0261-3.
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):1095-113. doi: 10.31083/j.rcm2204121.
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;25(1):70-4. doi: 10.1038/s41591-018-0240-2.
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;67(3):314-21. doi: 10.1097/MAT.0000000000001218.
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;2(4):626-34. doi: 10.1093/ehjdh/ztab080.
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;12(3):455. doi: 10.3390/jpm12030455.
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;2:584555. doi: 10.3389/fdgh.2020.584555.
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(12):970-80. doi: 10.11909/j.issn.1671-5411.2022.12.002.
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;148(9):765-77. doi: 10.1161/CIRCULATIONAHA.122.062646.
25. Cormen TT. *Algoritmos - Teoria e Prática*. Rio de Janeiro: Grupo Editorial Nacional; 2012.
26. Bhargava AY. *Entendendo Algoritmos: Um Guia Ilustrado Para Programadores e Outros Curiosos*. Rio de Janeiro: Novatec Editora; 2017.
27. Mill JG, Pinto K, Griep RH, Goulart A, Foppa M, Lotufo PA, et al. Medical Assessments and Measurements in ELSA-Brasil. *Rev Saude Publica*. 2013;47(Suppl 2):54-62. doi: 10.1590/s0034-8910.2013047003851.

*Material suplementar

Para informação adicional, por favor, clique aqui.



Este é um artigo de acesso aberto distribuído sob os termos da licença de atribuição pelo Creative Commons