

REVISÃO DE LITERATURA IDENTIFICADO

Aplicações da Inteligência Artificial no Diagnóstico da Doença de Chagas: Revisão de Escopo

ARTIFICIAL INTELLIGENCE IN THE DIAGNOSIS OF CHAGAS DISEASE: A SCOPING REVIEW

Vitor Comassetto Paes¹; Gabriel Henrique Carvalho Leite Romeiro¹; Lavínia Vital Quixadá Souza¹; Jessyca Lane Fausto Lira¹; Luciano Timbo Barbosa¹; Reinaldo dos Santos Moura²

1 Acadêmico(a) de Medicina, Centro Universitário de Maceió (UNIMA/Afya), Maceió/AL

2 Docente de Medicina, Centro Universitário de Maceió (UNIMA/Afya), Maceió/AL

E-mail do autor principal: reinaldo.santos@afya.com.br

Eixo Temático: Eixo 03 - Tecnologia e Inovação

RESUMO

A doença de Chagas é uma doença tropical negligenciada que afeta entre 6 e 7 milhões de pessoas, com diagnóstico tardio frequente em regiões endêmicas e escassez de ferramentas de rastreio de baixo custo. A inteligência artificial (IA) aplicada a exames já disponíveis, sobretudo o eletrocardiograma (ECG), surge como estratégia potencial para ampliar o rastreio e a estratificação de risco cardíaco na doença, mas a extensão dessa literatura ainda não foi mapeada. Objetivou-se mapear a extensão, a natureza e as lacunas da literatura sobre aplicações de IA no diagnóstico, rastreio ou estratificação de risco da doença de Chagas. Trata-se de revisão de escopo conduzida segundo a metodologia do Joanna Briggs Institute (JBI) e reportada conforme o checklist PRISMA-ScR, com buscas em PubMed/MEDLINE, LILACS/BVS e SciELO, sem restrição geográfica, resultando em 2.118 registros identificados, 1.512 após remoção automatizada de duplicatas, 27 estudos elegíveis após triagem por título e resumo e 14 estudos primários incluídos após leitura integral, que identificou também 2 duplicatas não capturadas pela deduplicação automatizada. Os 14 estudos incluídos, publicados entre 2013 e 2026, majoritariamente brasileiros, aplicaram desde redes neurais auto-organizáveis clássicas até redes profundas e modelos de ensemble a sinais de ECG e, em menor proporção, a imagens de microscopia, para rastreio da infecção, detecção de disfunção ventricular e estratificação de risco de morte súbita, com desempenho predominantemente satisfatório, mas ainda concentrado em coortes brasileiras específicas e sem padronização metodológica. Conclui-se que a IA aplicada ao diagnóstico da doença de Chagas é campo ativo e numericamente robusto, com mais de uma década de continuidade metodológica, impulsionado por coortes brasileiras de grande porte e por desafios computacionais compartilhados, com lacuna de validação externa multinacional fora do eixo Brasil-América do Norte.

Palavras-chave: Doença de Chagas. Inteligência Artificial. Eletrocardiografia. Aprendizado de Máquina. Diagnóstico.

ABSTRACT

Chagas disease is a neglected tropical disease affecting between 6 and 7 million people, with frequent delayed diagnosis in endemic regions and a shortage of low-cost screening tools. Artificial intelligence (AI) applied to

already available exams, particularly the electrocardiogram (ECG), has emerged as a potential strategy to expand screening and cardiac risk stratification in the disease, but the extent of this literature has not yet been systematically mapped. The objective was to map the extent, nature, and gaps in the literature on AI applications for the diagnosis, screening, or risk stratification of Chagas disease. This is a scoping review conducted according to the Joanna Briggs Institute (JBI) methodology and reported according to the PRISMA-ScR checklist, with searches in PubMed/MEDLINE, LILACS/BVS, and SciELO, without geographic restriction, resulting in 2,118 records identified, 1,512 after automated duplicate removal, 27 eligible studies after title and abstract screening, and 14 primary studies included after full-text reading, which also identified 2 duplicates not captured by automated deduplication. The 14 included studies, published between 2013 and 2026, mostly Brazilian, applied methods ranging from classic self-organizing neural networks to deep neural networks, ensemble models, and other machine learning techniques to ECG signals and, to a lesser extent, microscopy images, for infection screening, ventricular dysfunction detection, and sudden death risk stratification, with predominantly satisfactory diagnostic performance, but still concentrated in specific Brazilian cohorts and without methodological standardization across studies. It is concluded that AI applied to the diagnosis of Chagas disease is an active and numerically robust field with over a decade of methodological continuity, driven by large Brazilian cohorts and shared computational challenges, with a gap in multinational external validation and studies outside the Brazil-North America axis.

Keywords: Chagas Disease. Artificial Intelligence. Electrocardiography. Machine Learning. Diagnosis.

INTRODUÇÃO

A doença de Chagas, causada pelo protozoário *Trypanosoma cruzi*, é uma das doenças tropicais negligenciadas mais importantes, historicamente associada a áreas rurais da América Latina, mas atualmente reconhecida como problema de saúde global em decorrência da migração, urbanização e ampliação das rotas de transmissão, incluindo as vias congênita e oral¹. Sua ocorrência está fortemente relacionada aos Determinantes Sociais da Saúde (DSS), configurando-se como desafio para a Saúde Coletiva. Aproximadamente 30% dos infectados desenvolvem a forma cardíaca crônica, principal responsável pela morbimortalidade da doença, caracterizada por alterações eletrocardiográficas típicas cuja sistematização remonta aos trabalhos de Carlos Chagas, Evandro Chagas e Francisco Laranja².

O eletrocardiograma (ECG) permanece o exame mais utilizado no diagnóstico e acompanhamento da cardiopatia chagásica crônica, por ser amplamente disponível, de baixo custo e não invasivo, mas sua interpretação depende de profissionais capacitados, recurso escasso em regiões endêmicas². A Inteligência Artificial (IA), treinada em grandes bases de ECG digitalizados e impulsionada por desafios computacionais voltados à identificação da doença, vem ampliando as ferramentas de rastreio, diagnóstico e estratificação de risco. Ainda não havia síntese abrangente sobre a extensão dessa literatura, que envolve desde o rastreamento populacional da infecção até métodos de microscopia digital, com potencial de

contribuir para os ODS 3 e ODS 10. Diante dessa lacuna, esta revisão teve como objetivo mapear a extensão, a natureza e as lacunas da literatura sobre aplicações de IA no diagnóstico, rastreamento e estratificação de risco da doença de Chagas.

MÉTODO

Trata-se de revisão de escopo conduzida segundo a metodologia do JBI e reportada conforme o checklist PRISMA-ScR. A pergunta foi estruturada em formato PCC: pacientes, amostras biológicas ou sinais relacionados à doença de Chagas; aplicação de IA ou aprendizado de máquina para diagnóstico, rastreamento ou estratificação de risco; qualquer ambiente clínico, laboratorial ou de pesquisa, sem restrição geográfica ou de idioma. A busca foi realizada em PubMed/MEDLINE, LILACS/BVS e SciELO (Tabela 1), com estratégia ampla que não exigiu simultaneidade dos termos de IA e de Chagas.


Foram incluídos estudos primários que aplicaram IA ou aprendizado de máquina a dados clínicos, sinais (ECG) ou imagens (microscopia) para diagnóstico, rastreamento ou estratificação de risco em humanos, independentemente de desenho, idioma ou data; excluíram-se estudos sem modelo preditivo real, revisões, relatos de caso, editoriais, modelos pré-clínicos, menções secundárias e duplicatas já contabilizadas. A seleção ocorreu por título/resumo e leitura integral dos elegíveis, por revisor único, o que identificou 2 duplicatas adicionais não capturadas pela deduplicação automatizada.


A busca identificou 2.118 registros (PubMed 1.202; LILACS/BVS 907; SciELO 9); após remoção de 606 duplicatas, restaram 1.512, dos quais 27 foram elegíveis para leitura integral, que excluiu 13 (E1=3; E2=3; E3=3; E4=2; E5=2), resultando em 14 estudos na síntese final (Figura 1). Como limitações, destacam-se a seleção por revisor único e a heterogeneidade de modelos e metodologias, que dificultou comparações diretas.

Base	Estratégia (retrieval amplo, refinamento na triagem)
PubMed/MEDLINE	("Chagas disease"[Mesh] OR "Chagas disease"[tiab] OR "American trypanosomiasis"[tiab] OR "Trypanosoma cruzi"[tiab]) AND ("artificial intelligence"[tiab] OR "machine learning"[tiab] OR "deep learning"[tiab] OR "neural network"[tiab] OR "electrocardiogram"[tiab] OR "ECG"[tiab] OR "electrocardiography"[Mesh] OR algorithm[tiab] OR "predictive model"[tiab] OR "diagnostic model"[tiab])
LILACS/BVS	("doença de Chagas" OR "trypanossomiose americana" OR "Trypanosoma cruzi") AND ("inteligência artificial" OR "aprendizado de máquina" OR "eletrocardiograma" OR algoritmo OR rede neural)
SciELO	("doença de Chagas") AND ("inteligência artificial" OR "aprendizado de máquina" OR algoritmo)

Tabela 1. Estratégias de busca por base de dados, sem restrição de data ou idioma. Refinamento de especificidade (presença simultânea de termo de IA e de sinal/imagem diagnóstico) aplicado na etapa de triagem, não na própria busca.

Figura 1. Fluxograma PRISMA-ScR.





Nota: E1 ausência de modelo computacional preditivo/diagnóstico (apenas estatística clínica ou índice padrão); E2 não é estudo primário (revisão/relato de caso); E3 doença de Chagas mencionada apenas secundariamente; E4 modelo pré-clínico sem aplicação humana; E5 duplicata de dado/análise já contabilizada.

RESULTADOS E DISCUSSÃO

Os 14 estudos incluídos (Figura 1; Tabela 2), publicados entre 2013 e 2026, evidenciaram crescimento progressivo do uso da IA aplicada à doença de Chagas, com predominância de pesquisas brasileiras e delineamentos observacionais; nenhum foi ensaio clínico randomizado. O ECG foi a principal fonte de dados (12 estudos), e dois utilizaram microscopia digital para detecção direta do T. cruzi.

O estudo pioneiro de Souza Neto et al.³ (2013) já usava variabilidade de frequência cardíaca do ECG em rede neural auto-organizável para diferenciar cardiopatas, indeterminados e saudáveis. Na década seguinte, Jidling et al.⁴ treinaram rede neural convolucional sobre mais de 2 milhões de ECGs das coortes brasileiras CODE e SaMi-Trop, com AUC-ROC de 0,80 na validação interna, mas queda para 0,59-0,68 em coortes externas, evidenciando o desafio de generalização da IA em saúde. Fonseca et al.⁵ combinaram IA-ECG a variáveis clínicas em campanha comunitária, com sensibilidade elevada para casos suspeitos, reforçando o potencial de triagem em áreas endêmicas.

Na identificação de complicações cardíacas, Ribeiro et al.⁶ classificaram gravidade de insuficiência cardíaca via biomarcadores espectrais do ECG-Holter (AUC 0,75-0,83); na coorte SaMi-Trop, Brito et al.⁷ validaram a IA-ECG para disfunção sistólica do ventrículo esquerdo e Cardoso et al.⁸ estenderam o modelo para valor prognóstico comparável ao NT-proBNP. Na estratificação de risco de morte súbita, Silva et al.⁹, Pedrosa et al.¹⁰ e Cavalcante et al.¹¹ aplicaram algoritmos sobre ECG-Holter e dados clínicos, com sensibilidade superior a 90% e AUC elevada em mais de um estudo.

O rastreamento automatizado pelo ECG bruto foi mais modesto: os três estudos do PhysioNet/CinC Challenge 2025¹²⁻¹⁴ (wavelet scattering, atenção e aprendizado hierárquico) tiveram desempenho intermediário no teste final, indicando que a detecção por sinal isolado

permanece desafio metodológico. Fora do ECG, Lin et al.¹⁵ e Chenni et al.¹⁶ aplicaram IA à microscopia digital com elevada acurácia na identificação do parasita, com potencial para descentralizar o diagnóstico em regiões com escassez de especialistas.

No conjunto, a IA vem sendo aplicada em três domínios (rastreamento da infecção, complicações cardíacas e microscopia digital), com melhor desempenho nos dois últimos. Esses achados têm relevância estratégica para a Saúde Coletiva ao reduzir barreiras dos DSS em regiões endêmicas. Observou-se, porém, forte concentração em poucas coortes brasileiras (SaMi-Trop e CODE) e heterogeneidade de algoritmos e métricas, o que limita comparações; validação externa e avaliação de impacto clínico são necessárias para consolidar a incorporação da IA à prática assistencial.

Autor/Ano	Aplicação diagnóstica	N	Modelo	Principal métrica
Souza Neto J et al., 2013	Suporte ao diagnóstico da forma cardíaca via VFC	NI	Rede neural auto-organizável (Kohonen)	Escalogramas superiores a indicadores temporais ($p < 0,05$).
Jidling C et al., 2023	Rastreio da infecção via ECG	> 2 milhões de ECGs	Rede neural convolucional	AUC-ROC 0,80 (interna); 0,68 e 0,59 (externas).
Fonseca IMG et al., 2026	Rastreio comunitário via ECG + clínica	1.115 adultos	IA-ECG + 3 variáveis clínicas	Sensibilidade 100%; especificidade 40%.
Ribeiro P et al., 2026	Gravidade de IC chagásica via ECG-Holter	380 pacientes	Classificadores sobre biomarcador espectral	AUC 0,75-0,83 conforme par de gravidade.
Brito BOF et al., 2021	Disfunção ventricular (DSVE) via IA-ECG	1.304 pacientes	Rede neural (IA-ECG)	Acurácia 83%; sensibilidade 73%.
Cardoso CS et al., 2026	DSVE e mortalidade via IA-ECG (mesma coorte)	1.304-1.547 pacientes	Rede neural (IA-ECG)	C-index 0,78 (mortalidade em 9 anos).
Silva LEV et al., 2022	Risco em cardiomiopatia (escore de Rassi)	31 pacientes	Máquina de vetor de suporte	FI 0,61.
Pedrosa RC et al., 2024	Risco de morte súbita além da FEVE	221 pacientes	Árvore de classificação	AUC 0,96 (índice de repolarização).
Cavalcante CHL et al., 2023	Risco de morte súbita multiparamétrico	315 pacientes	Seleção de atributos + Naïve Bayes	Sensibilidade 90,6%; AUC 80,6%.
Patidar S, 2026	Rastreio via ECG (desafio PhysioNet/CinC)	Base do desafio	Wavelet scattering + RUSBoost	Pontuação do desafio 20,5%.
Im H et al., 2026	Rastreio via ECG (desafio PhysioNet/CinC)	Base do desafio	Atenção cruzada híbrida	Pontuação do desafio 21,8%.
Wen H, Kang J, 2026	Rastreio via ECG (desafio PhysioNet/CinC)	Base do desafio	Aprendizado hierárquico	Pontuação do desafio 16,3%.
Lin L et al., 2026	Deteção do parasita em microscopia	478 imagens humanas	SSD-MobileNetV2/YOLOv8	Precisão 86%; sensibilidade 87%.
Chenni K et al., 2025	Deteção do parasita em vídeo	23 vídeos	Deteção por movimento + MobileNetV2	Acurácia 99,6%; AUC-ROC 1,0.

Tabela 2. Síntese dos 14 estudos primários incluídos, em ordem de citação no texto. NI = não informado; IC = insuficiência cardíaca; FEVE = fração de ejeção do ventrículo esquerdo; DSVE = disfunção sistólica do ventrículo esquerdo; VFC = variabilidade de frequência cardíaca.

CONCLUSÃO

A aplicação de IA ao diagnóstico da doença de Chagas é campo numericamente robusto e metodologicamente diverso, impulsionado por coortes brasileiras de grande porte e por um desafio computacional público dedicado à detecção da doença via ECG. O desempenho foi geralmente satisfatório para detecção de disfunção ventricular e identificação do parasita em microscopia, mas mais modesto para o rastreio direto da infecção por sinal eletrocardiográfico isolado. Parte da evidência sobre disfunção ventricular deriva da mesma coorte (SaMi-Trop), reutilizada com objetivos diagnóstico e prognóstico complementares, o que reduz a independência amostral do conjunto.

A literatura atual não sustenta a adoção clínica indiscriminada desses modelos, sobretudo para o rastreio populacional direto da infecção. As perspectivas futuras envolvem validação externa multinacional fora do eixo Brasil-América do Norte, padronização

metodológica e integração a fluxos assistenciais reais; a seleção por revisor único e a ausência de bases pagas ou literatura cinza reforçam a necessidade de replicação futura com metodologia mais robusta.

REFERÊNCIAS

1. Ferreira MDS, Maldonado RA, Farani PSG. Chagas Disease in the 21st Century: Global Spread, Ecological Shifts, and Research Frontiers. *Biology (Basel)*. 2025;14(11). doi:10.3390/biology14111631.
2. Hasslocher-Moreno AM, Saraiva RM, Silva Júnior TLD, Xavier SS, Sousa AS. Exploring the Historical Background and Clinical Implications of Electrocardiogram in the Context of Chagas Disease Research. *Rev Soc Bras Med Trop*. 2023;56:0506.
3. Souza Neto J, Carvalho JLA, Rocha AF, Junqueira Junior LF, Nascimento FAO. Sistema de apoio ao diagnóstico da Doença de Chagas baseado em escalogramas e redes neurais auto-organizáveis. *Rev Bras Eng Biomed*. 2013;29(3):242-253.
4. Jidling C, Gedon D, Schön TB, Oliveira CDL, Cardoso CS, Ferreira AM, et al. Screening for Chagas disease from the electrocardiogram using a deep neural network. *PLoS Negl Trop Dis*. 2023;17(7):e0011118.
5. Fonseca IMG, Nunes MCP, Sable C, Mendoza RF, Santos FLN, Gomes PR, et al. Artificial Intelligence-Enhanced Electrocardiography Analysis for Diagnosing Chagas Disease. *Arq Bras Cardiol*. 2026;123(5):e20260032.
6. Ribeiro P, Marques JAL, Barbosa MI, Pedrosa RC, do Vale Madeiro JP, Miguel Rodrigues P. Machine learning-based stratification of chagas heart failure severity using ECG power spectral biomarkers. *Med Biol Eng Comput*. 2026;64(6):2163-2176.
7. Brito BOF, Attia ZI, Martins LNA, Perel P, Nunes MCP, Sabino EC, 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*. 2021;15(12):e0009974.
8. Cardoso CS, Mangold K, Padilha da Silva JL, Di Lorenzo Oliveira C, Ferreira AM, Oliveira da Silva LC, et al. AI-ECG for Detecting Left Ventricular Systolic Dysfunction in Chagas Disease: Diagnostic and Prognostic Value. *JACC Adv*. 2026;5(7):102878.
9. Silva LEV, Moreira HT, de Oliveira MM, Cintra LSS, Salgado HC, Fazan R Jr, et al. Heart rate variability as a biomarker in patients with Chronic Chagas Cardiomyopathy with or without concomitant digestive involvement and its relationship with the Rassi score. *Biomed Eng Online*. 2022;21(1):44.
10. Pedrosa RC, Paulo do Vale Madeiro J, Alberto AC, Limeira GA, de Bragança Pereira B, Matos do Nascimento E, et al. Risk stratifier for sudden cardiac death beyond the left ventricular ejection fraction in Chagas cardiomyopathy. *Pacing Clin Electrophysiol*. 2024;47(2):312-320.
11. Cavalcante CHL, Primo PEO, Sales CAF, Caldas WL, Silva JHM, Souza AH, et al. Sudden cardiac death multiparametric classification system for Chagas heart disease's patients based on clinical data and 24-hours ECG monitoring. *Math Biosci Eng*. 2023;20(5):9159-9178.
12. Patidar S. Automated detection of Chagas disease from ECG signals using wavelet scattering transform and RUSBoost classifier. *Physiol Meas*. 2026;47(3). doi:10.1088/1361-6579/ae4b82.
13. Im H, Lee N, Kang T, Kim T, Kim D, Lee D, et al. Auxiliary-conditioned cross-attention with physiologically interpretable features for chagas disease detection from 12-lead ECGs. *Physiol Meas*. 2026;47(7). doi:10.1088/1361-6579/ae8b72.
14. Wen H, Kang J. Reliability-aware hierarchical learning for Chagas disease screening from 12-lead ECGs: tackling label uncertainty and class imbalance. *Physiol Meas*. 2026. doi:10.1088/1361-6579/ae98e0.
15. Lin L, Solano AV, Gonzales F, Torrico MC, Illanes D, Díez N, et al. Artificial intelligence algorithm for real-time detection and counting of *Trypanosoma cruzi* parasites using smartphone microscopy. *PLoS Negl Trop Dis*. 2026;20(5):e0012955.
16. Chenni K, Brito-Loeza C, Karabağ C, Rada L. From Detection to Motion-Based Classification: A Two-Stage Approach for *T. cruzi* Identification in Video Sequences. *J Imaging*. 2025;11(9). doi:10.3390/jimaging11090315.