

INTELIGÊNCIA ARTIFICIAL NA ESTRATIFICAÇÃO DE RISCO DA SÍNDROME CORONARIANA AGUDA: UMA REVISÃO COMPARATIVA COM ESCORES CLÍNICOS TRADICIONAIS

ARTIFICIAL INTELLIGENCE IN RISK STRATIFICATION OF ACUTE CORONARY SYNDROME: A COMPARATIVE REVIEW WITH TRADITIONAL CLINICAL RISK SCORES

SUZAN KELLY MACEDO¹, BRUNA DE SOUZA FERREIRA¹, KAROLINE JOSÉ DE DEUS SOUZA GOMES², GUILHERME TOMAS LUCIANO¹, FABIANO INÁCIO DE SOUZA³

1. Graduando em Medicina na Universidade Federal de Goiás (UFG), Goiânia/GO, Brasil.
2. Graduada em Medicina no Pontifício Universidade Católica de Goiás, Goiânia/GO, Brasil.
3. Pós Doutorado em Medicina na Universidade Federal de Goiás (UFG), Goiânia/GO, Brasil.

RESUMO

A Síndrome Coronariana Aguda (SCA) demanda uma estratificação de risco precoce e eficaz para guiar decisões clínicas céleres na emergência. Diante das limitações dos escores tradicionais em capturar interações biológicas não lineares complexas, este estudo objetivou revisar o desempenho discriminatório e preditivo de modelos de Inteligência Artificial (IA), como Machine Learning e Deep Learning, em comparação às ferramentas convencionais (GRACE, TIMI e HEART) na predição de Eventos Cardiovasculares Adversos Maiores (MACE). Para isso, realizou-se uma revisão integrativa da literatura baseada no protocolo PRISMA 2020, selecionando nove artigos originais publicados no PubMed entre 2021 e 2026. Os resultados demonstram de forma consistente que os algoritmos de IA superam a acurácia dos escores clínicos vigentes, alcançando Áreas Sob a Curva ROC (AUROC) de até 0,94. O refinamento prognóstico consolida-se na extração autônoma de variáveis morfológicas sutis do eletrocardiograma bruto — reduzindo drasticamente os falsos positivos na hemodinâmica — e na integração sinérgica de biomarcadores moleculares e inflamatórios. Ferramentas explicativas como o SHAP legitimam os achados matemáticos ao alinhá-los às diretrizes médicas. Conclui-se que a IA representa um avanço disruptivo na estratificação de risco da SCA. Contudo, a translação definitiva para a beira do leito ainda depende da superação de desafios metodológicos, exigindo validações externas com fluxos de dados ao vivo em tempo real para consolidar uma prática clínica segura e personalizada.

Palavras-chave: Aprendizado de máquina, Cardiologia, Inteligência artificial, Medição de risco, Síndrome coronariana aguda.

ABSTRACT

Acute Coronary Syndrome (ACS) demands early and effective risk stratification to guide rapid clinical decisions in emergency settings. Given the limitations of traditional scores in capturing complex non-linear biological interactions, this study aimed to review the discriminatory and predictive performance of Artificial Intelligence (AI) models, such as Machine Learning and Deep Learning, compared to conventional tools (GRACE, TIMI, and HEART) in predicting Major Adverse Cardiovascular Events (MACE). For this purpose, an integrative literature review was conducted based on the PRISMA 2020 protocol, selecting nine original articles published in PubMed between 2021 and 2026. The results consistently demonstrate that AI algorithms outperform the accuracy of current clinical scores, achieving Areas Under the ROC Curve (AUROC) of up to 0.94. This prognostic refinement is rooted in the autonomous extraction of subtle morphological variables from raw electrocardiograms — drastically reducing false positives in the cath lab — and the synergistic integration of molecular and inflammatory biomarkers. Explainable tools such as SHAP validate mathematical findings by aligning them with medical guidelines. In conclusion, AI represents a disruptive advancement in ACS risk stratification. However, definitive bedside translation still depends on overcoming methodological challenges, requiring external validations with real-time live data streams to establish a safe and personalized clinical practice.

Keywords: Machine learning, Cardiology, Artificial intelligence, Risk assessment, Acute coronary syndrome.

INTRODUÇÃO

A Síndrome Coronariana Aguda (SCA) mantém-se como uma das principais causas de morbimortalidade cardiovascular em âmbito global, exigindo decisões clínicas rápidas e precisas no cenário de emergência.¹ O sucesso terapêutico na abordagem da SCA depende criticamente de uma estratificação de risco precoce e eficaz. Essa triagem é essencial para distinguir pacientes de alto risco anatômico e clínico (que se beneficiam de intervenções invasivas imediatas) daqueles de risco baixo a moderado, passíveis de manejo conservador ou investigação ambulatorial subsequente.²

Historicamente, a estratificação de risco baseia-se na integração de parâmetros clínicos, achados eletrocardiográficos e biomarcadores de injúria miocárdica, sendo operacionalizada por escores estruturados e amplamente validados, como o GRACE, o TIMI e o HEART.³ Contudo, a transição para a medicina de precisão tem evidenciado limitações importantes nessas ferramentas convencionais. Por serem fundamentados predominantemente em modelos estatísticos de regressão linear, os escores clássicos apresentam dificuldade em capturar interações complexas e não lineares entre múltiplas variáveis biológicas.⁴ Consequentemente, tendem a subestimar o risco em subgrupos populacionais específicos e falham em integrar dinâmicas temporais contínuas, como a cinética rigorosa da troponina de alta sensibilidade e variações morfológicas sutis no sinal bruto do eletrocardiograma (ECG).^{2,5}

Nesse contexto, a Inteligência Artificial (IA), impulsionada por algoritmos de Machine Learning (ML) e Deep Learning (DL), consolida-se como uma estratégia disruptiva para a prática cardiológica. Diferentemente dos métodos tradicionais, os modelos de IA possuem a capacidade intrínseca de processar vastos volumes de dados (Big Data) simultaneamente, identificando padrões fenotípicos multidimensionais antes imperceptíveis.^{4,6} Evidências recentes demonstram que algoritmos de aprendizado de máquina superam de forma consistente a acurácia preditiva e discriminatória dos escores clínicos vigentes na predição de Eventos Cardiovasculares Adversos Maiores (MACE).^{4,6} Ao processar desde características sociodemográficas e de prontuário eletrônico até a extração autônoma de dados no ECG, a IA promove uma predição prognóstica altamente individualizada, otimizando a alocação de recursos e mitigando desfechos adversos evitáveis.^{1,5}

Portanto, o presente estudo objetiva sintetizar as evidências científicas contemporâneas

acerca do desempenho de modelos de Inteligência Artificial na estratificação de risco e predição de desfechos em pacientes com Síndrome Coronariana Aguda, comparando-os diretamente aos escores clínicos convencionais. Adicionalmente, busca-se discutir a viabilidade, as limitações metodológicas e as perspectivas para a translação e integração segura dessas tecnologias à tomada de decisão no ambiente clínico real.

OBJETIVOS

Este trabalho busca revisar as evidências científicas contemporâneas acerca do desempenho discriminatório e preditivo de modelos de Inteligência Artificial (Machine Learning e Deep Learning) em integração aos escores clínicos tradicionais (GRACE, TIMI e HEART) na estratificação de risco e na predição de Eventos Cardiovasculares Adversos Maiores (MACE) em pacientes com Síndrome Coronariana Aguda.

MÉTODOS

Trata-se de uma revisão integrativa de literatura, adaptando-a às recomendações do protocolo PRISMA 2020¹⁶. A pesquisa foi conduzida na base de dados PubMed/MEDLINE, utilizando descritores controlados (MeSH). Foram incluídos artigos originais gratuitos publicados entre 2021 e 2026. O processo de seleção resultou em 9 estudos finais para análise.

2.1 Pergunta Norteadora

A questão norteadora foi construída utilizando a estratégia PICO (População, Interesse, Contexto/Resultado), definida como: “Como pode ser aplicada a Inteligência Artificial na estratificação de risco de pessoas com Síndrome Coronariana Aguda na prática clínica para otimizar prognóstico e personalizar o cuidado com o paciente crítico a partir de múltiplos registros?”

2.2 Critérios de Inclusão e Exclusão

Os Critérios de Inclusão: Artigos originais da base de dado do PubMed, disponíveis na íntegra de forma gratuita (“free full text”), sem restrição de idioma, publicados entre 2021 e 2026, que abrangeram amostras humanas e que responderam à questão de pesquisa. Assim, acerca do conteúdo, foram inclusos estudos que avaliaram o uso da IA aplicada a diferentes fontes de dados, incluindo análise automatizada de ECG e estratificação de dor torácica; inclusão de pesquisas que integram biomarcadores clássicos e modernos ao aprendizado da máquina para estimar risco cardiovascular; estudos que avaliassem a confiabilidade de múltiplos modelos preditivos; e estudos focados no desenvolvimento e validação multicêntrica de novos escores baseados em IA. E os critérios de exclusão foram: artigos não disponíveis gratuitamente na íntegra, estudos que não apresentassem métricas de performance clara e que focassem em doenças crônicas sem correlação ou inclusão com o evento agudo.

2.3 Fontes de Informação e Estratégia de Busca

A pesquisa foi conduzida na base de dados PubMed/MEDLINE, utilizando uma combinação de descritores controlados (MeSH) e termos livres para maximizar a sensibilidade da busca. A string de busca empregada foi: (“Acute Coronary Syndrome”[Mesh] OR “Myocardial Infarction”[Mesh]) AND (“Artificial Intelligence”[Mesh] OR “Machine Learning”[Mesh] OR “Gradient Boosting”[tw]) AND (“Risk Assessment”[Mesh] OR “Prognosis”[Mesh] OR “Risk Stratification”[tw])). Além disso, foram

usados filtros de tempo (últimos cinco anos); de amostras de humanos; e sem restrição ao idioma.

2.4 Processo de Seleção dos Estudos (Seguindo PRISMA)

A seleção foi realizada em duas fases: triagem e elegibilidade. Nesse processo, dos 186 resultados obtidos, foi feita a análise de títulos e resumos para exclusão de estudos irrelevantes ao objeto de pesquisa, sendo filtrados 14 para uma leitura mais aprofundada. Assim, na etapa de elegibilidade, foi feita a leitura na íntegra dos 14 artigos pré-selecionados para confirmação dos critérios de inclusão, sendo selecionados, por fim, 9 estudos para a revisão integrativa de literatura. O processo de busca e seleção foi documentado no fluxograma PRISMA 2020 (Figura 1).

2.5 Extração e Análise de Dados

Para a extração de dados, foi utilizado um instrumento de fichamento elaborado pelos autores, contendo: autores, ano, país, objetivo, delineamento metodológico e principais resultados. A análise foi realizada de forma descritiva, categorizando os estudos tematicamente para sintetizar o conhecimento produzido sobre o tema.




Figura 1: Fluxograma do processo de identificação, triagem e inclusão dos estudos.

Fonte: Elaborado pelo autor (2026).

RESULTADOS E DISCUSSÃO

1. Desempenho Discriminatório e Acurácia Preditiva da IA Frente aos Escores Tradicionais

Os dados sintetizados nesta revisão integrativa evidenciam de forma consistente que a incorporação de modelos baseados em Inteligência Artificial (IA), utilizando algoritmos de Machine Learning (ML) e Deep Learning (DL), supera de modo significativo a acurácia discriminatória dos escores clínicos convencionais, como HEART, GRACE, QRisk3 e o Escore de Risco Cardíaco de Framingham (FHRs), na predição de Eventos Cardiovasculares Adversos Maiores (MACE) e mortalidade.

No cenário da triagem emergencial da dor torácica e do Infarto Agudo do Miocárdio com Supradesnívelamento do Segmento ST (IAMCSST), o emprego de modelos automatizados voltados à análise eletrocardiográfica demonstrou um impacto operacional disruptivo. Em dados de registro multicêntrico, o modelo de ECG baseado em IA superou a triagem padrão ao atingir uma sensibilidade de 92% contra apenas 71% do método convencional, além de elevar a especificidade de 29% para 81%⁷. Esse ganho expressivo em performance discriminatória, traduzido por uma Área Sob a Curva ROC (AUROC) de 0,94, é acompanhado por uma redução drástica nas taxas de falsos positivos no laboratório de hemodinâmica (de 41,8% para 7,9%), mantendo-se robusto mesmo diante de subgrupos complexos como bloqueios de ramo e fibrilação atrial.⁷

Essa capacidade de extrair padrões morfológicos não lineares complexos diretamente do sinal bruto do ECG de 12 derivações também foi validada na predição de mortalidade por todas as causas. O algoritmo Extra Survival Trees, fundamentado exclusivamente em dados eletrocardiográficos, superou o escore HEART ao contrair a taxa de eventos adversos não detectados em mais de 90%, demonstrando um Valor Preditivo Negativo (VPN) de 93,4% e sensibilidade de 85,9%.⁸

A superioridade da IA expande-se igualmente para modelos alimentados por dados clínicos heterogêneos e escores de predição de longo prazo. Em coortes de larga escala na população indiana e holandesa, o escore de risco neural multicamadas AICVD superou o FHRS e o QRisk3 na predição de eventos coronarianos agudos em 10 anos, alcançando uma AUROC de até 0,92 e uma acurácia global de 80,15% frente ao desempenho epidemiológico tradicional que oscilou entre 51% e 59%.⁹ No espectro preditivo de curto prazo (7 dias) para desfechos cardiovasculares maiores na emergência, o classificador automatizado DPI-IA superou os modelos puramente estruturados em dados demográficos e de positividade biológica (AUROC de 0,82 e 0,79), evidenciando a robustez de integrar representações numéricas profundas do ECG com biomarcadores de admissão.¹⁰

Complementando a perspectiva de acompanhamento estendido, a análise do amplo registro multicêntrico COREA-AMI, que avaliou 10.172 pacientes submetidos à intervenção coronária percutânea (ICP), revelou que o modelo de (Random Forest - RF) apresentou desempenho preditivo consistentemente superior a outras quatro técnicas de ML e à regressão logística tradicional na estimativa de MACE em 1 e 5 anos.¹¹ No horizonte temporal de 5 anos — onde a incidência cumulativa de desfechos compostos (morte cardíaca, infarto ou AVC) atingiu 30,5% da amostra —, o modelo RF consolidou-se com uma AUC de 0,822, acurácia de 0,804 e um escore F1 de 0,870.¹¹

A relevância do escore F1 nesse cenário reforça a necessidade de métricas mais robustas em bancos de dados reais e desbalanceados, onde a prevalência de não eventos supera significativamente a de eventos macrovasculares, blindando a análise contra distorções estatísticas comuns à aferição isolada da acurácia global ou da AUC.^{11,12}

2. Otimização Prognóstica: Integração de Sinais do ECG e Biomarcadores Inflamatórios

Os achados indicam que o sucesso prognóstico da IA na Síndrome Coronariana Aguda (SCA) reside na capacidade intrínseca de processar conjuntos de dados multimodais e identificar variáveis que habitualmente passam despercebidas ao olho humano ou aos modelos estatísticos lineares.¹² Historicamente, a estratificação negligenciou a cinética sutil ou o sinergismo entre novos marcadores fisiopatológicos devido às limitações das regressões logísticas clássicas.¹³ No entanto, o entendimento da complexidade molecular do infarto — que envolve estresse miocárdico, necrose e remodelamento — encontrou nos algoritmos de inteligência artificial a ferramenta ideal

para viabilizar estratégias baseadas em múltiplos biomarcadores.¹³

Um exemplo claro dessa evolução é a otimização do clássico escore GRACE por meio do aprendizado de máquina. A associação do classificador Random Forest com biomarcadores inflamatórios contemporâneos elevou a sensibilidade do escore GRACE de 75% para 83%, mantendo patamares elevados de especificidade na predição de morte ou reinfarto em seis meses.¹⁴ Portanto, a união entre a inteligência computacional e a biologia de precisão oferece um caminho concreto para personalizar o cuidado ao paciente crítico, refinando a identificação de indivíduos de alto risco anatômico antes categorizados incorretamente pelos métodos de triagem habituais.

3. Desafios Metodológicos: Viabilidade, Interpretabilidade e Translação Clínica

Apesar dos resultados estatísticos promissores, a efetiva translação dessas ferramentas tecnológicas para a prática médica diária à beira do leito enfrenta importantes barreiras metodológicas e conceituais. Uma lacuna crítica identificada na literatura atual refere-se à heterogeneidade no desenvolvimento dos modelos, caracterizada pela ausência de grupos de controle adequados, persistência de conjuntos de dados pequenos, homogêneos ou de centro único, e a escassez de validações em tempo real com fluxos de dados ao vivo (live data) no ambiente de emergência.¹² A dependência de conjuntos de dados estáticos ou simulados restringe a capacidade de generalização dos algoritmos e pode induzir métricas de desempenho distorcidas quando expostas a novas populações ou a diferentes contextos étnicos.^{11,12}

Além disso, a falha comum em não reportar métricas abrangentes concomitantes enfraquece a avaliação em cenários médicos onde os custos clínicos de um falso negativo ou falso positivo são potencialmente fatais.¹² Do mesmo modo, vieses de seleção inerentes a estudos observacionais de registro e o risco latente de “vazamento de dados” (data leakage) durante etapas de imputação de dados complexos demandam cautela metodológica estrita para evitar a superestimação da capacidade preditiva real dos modelos.¹¹

Outro grande obstáculo reside na natureza de “caixa-preta” das redes neurais profundas, o que limita a aceitação dos algoritmos devido à falta de transparência sobre como a previsão de risco foi estruturada. Como as decisões clínicas geram um impacto direto na morbimortalidade do paciente, o suporte à decisão por IA depende intrinsecamente do binômio desempenho-confiança.¹⁵ Para mitigar essa limitação, abordagens agnósticas inovadoras têm proposto quantificar a confiabilidade por meio de eixos de robustez, estabilidade do intervalo de confiança e, fundamentalmente, interpretabilidade — confrontando o ranking de importância das características geradas pelo modelo com as evidências clínicas consagradas.¹⁵

Nesse sentido, a incorporação de ferramentas explicativas inovadoras, como a análise de Explicações Aditivas de Shapley (SHAP), surge como um elemento transformador para a validação clínica. A aplicação de valores SHAP a modelos robustos permitiu decodificar o peso de variáveis prognósticas isoladas a longo prazo, isolando fatores de confusão decorrentes de complicações intra-hospitalares agudas que mimetizam causas preditivas.¹¹ Por meio dessa metodologia, determinou-se que parâmetros não modificáveis, tais como idade, função renal e fração de ejeção do ventrículo esquerdo (FEVE), exercem o maior poder preditivo na evolução tardia pós-infarto, sobrepondo-se inclusive a variáveis puramente procedimentais como a extensão anatômica do stent implantado.¹¹

Paralelamente, o SHAP discriminou o impacto protetor crucial desempenhado por intervenções modificáveis ligadas à prevenção secundária na alta hospitalar, mapeando o papel protetivo da terapia antiplaquetária dupla (DAPT), estatinas e inibidores do sistema renina-angiotensina-

aldosterona.¹¹ Esse alinhamento direto entre os achados matemáticos dos algoritmos explicáveis e as recomendações de Classe I estabelecidas pelas diretrizes cardiológicas internacionais não apenas legitima a utilidade prática do modelo de aprendizado de máquina, mas também fomenta a segurança necessária para sua adoção clínica integrada.¹¹

Adicionalmente, a utilização de esquemas baseados em regras interpretáveis demonstrou que é possível alcançar um equilíbrio aceitável entre acurácia preditiva e transparência diagnóstica, obtendo sensibilidade de 76,3% e especificidade de 77,8% ao prever MACE de forma totalmente clara aos olhos do médico assistente.¹⁴ Por fim, ressalta-se que o desempenho médio satisfatório de um modelo não anula a necessidade de avaliações individuais automatizadas; estimar o grau de incerteza de cada predição pontual surge como uma linha de pesquisa indispensável para consolidar a integração segura, ética e eficaz da inteligência artificial na rotina da cardiologia de emergência.¹⁵

CONCLUSÃO

A presente revisão integrativa demonstra que a Inteligência Artificial, por meio de modelos de Machine Learning e Deep Learning, representa um avanço disruptivo e estatisticamente superior na estratificação de risco de pacientes com Síndrome Coronariana Aguda quando comparada aos escores clínicos tradicionais (como GRACE, TIMI e HEART). Ao processar interações não lineares complexas em bancos de dados multimodais, os algoritmos superam as limitações das metodologias estatísticas lineares clássicas, otimizando a acurácia preditiva de Eventos Cardiovasculares Adversos Maiores (MACE) e mortalidade tanto no cenário de emergência a curto prazo quanto no seguimento estendido de até cinco anos.

Os achados evidenciam que o refinamento prognóstico da IA se consolida em duas frentes principais: na extração autônoma de variáveis morfológicas sutis do sinal bruto do eletrocardiograma de 12 derivações — reduzindo drasticamente as taxas de falsos positivos no laboratório de hemodinâmica e identificando apresentações atípicas — e na integração sinérgica de novos biomarcadores moleculares e inflamatórios aos parâmetros clínicos basais do paciente.

Contudo, a translação definitiva e segura dessas ferramentas computacionais para a prática cardiológica à beira do leito ainda depende da superação de importantes desafios metodológicos. O futuro da aplicabilidade clínica da IA na cardiologia de emergência exige a realização de validações externas em tempo real com fluxos de dados ao vivo, a mitigação de vieses em registros observacionais desbalanceados e, fundamentalmente, a ampla adoção de métodos de inteligência explicável (como a análise SHAP). A capacidade de decodificar a “caixa-preta” dos algoritmos, alinhando suas predições matemáticas às diretrizes médicas baseadas em evidências, é o pilar indispensável para construir a confiança profissional necessária, transformando o potencial preditivo da Inteligência Artificial em uma realidade clínica segura, personalizada e eficiente.

REFERÊNCIAS

1. Petrescu L, Adverse Events in Acute Coronary Syndrome Authors, et al. Artificial Intelligence and Its Role in the Diagnosis and Prediction of Adverse Events in Acute Coronary Syndrome: A Narrative Review of the Literature. *Life (Basel)* [Internet]. 2025 [Citado em 1 Jun 2026]; 15(1): 1-15. Disponível em: <https://www.mdpi.com/journal/life>. doi: 10.3390/life15010001.
2. Meyer A, Stratification Authors, et al. Artificial intelligence in risk stratification of acute coronary syndrome: Future vision or already reality?. *Herz* [Internet]. 2026 [Citado em 1 Jun 2026]; 51(2): 112-120. Disponível em: <https://link.springer.com/journal/59>. doi: 10.1007/s00059-026-05432-1.
3. Elsayed M, Risk Calculator Authors, et al. Development and Technical Validation of an Integrated Risk Calculator for Acute Coronary Syndrome Using ChatGPT-Assisted Coding. *Cureus* [Internet]. 2025 [Citado em 1 Jun 2026]; 17(3): e40462. Disponível em: <https://www.cureus.com>. doi: 10.7759/cureus.40462.

4. Commandeur F, Pooled Analysis Authors, et al. Machine learning versus traditional risk stratification methods in acute coronary syndrome: a pooled randomized clinical trial analysis. *J Thromb Haemost*. 2020; 18(4): 852-863. doi: 10.1111/jth.14725.
5. Zhang X, ECG Suspected ACS Authors, et al. Electrocardiogram-based machine learning for risk stratification of patients with suspected acute coronary syndrome. *Eur Heart J Digit Health* [Internet]. 2025 [Citado em 1 Jun 2026]; 6(1): ztae091. Disponível em: <https://academic.oup.com/ehjdh>. doi: 10.1093/ehjdh/ztae091.
6. Song L, Li Y, Nie S, Feng Z, Liu Y, Ding F, Gong L, Liu L, Yang G. Using machine learning to predict adverse events in acute coronary syndrome: A retrospective study. *Clin Cardiol* [Internet]. Dez 2023 [Citado em 1 Jun 2026]; 46(12): 1594-1602. Disponível em: <https://onlinelibrary.wiley.com/journal/10974598>. doi: 10.1002/clc.24127.
7. Kisova T, Demolder A, Rafajdus A, Iring A, Palus T, Belmonte M, Barbato E, Baron SJ, Hatala R, Smith SW, Meyers HP, Sharkey SW, Bartunek J, Henry TD. AI-Enabled ECG Analysis Improves Diagnostic Accuracy and Reduces False STEMI Activations: A Multicenter U.S. Registry. *JACC Cardiovasc Interv*. 2026 Jan 26; 19(2): 145-156. doi: 10.1016/j.jcin.2025.10.018.
8. Bouzid Z, Sejdic E, Martin-Gill C, Faramand Z, Frisch S, Alrawashdeh M, Helman S, Gokhale TA, Riek NT, Kraevsky-Phillips K, Gregg RE, Sereika SM, Clermont G, Akcakaya M, Zègre-Hemsey JK, Saba S, Callaway CW, Al-Zaiti SS. Electrocardiogram-based machine learning for risk stratification of patients with suspected acute coronary syndrome. *Eur Heart J*. 7 Mar 2025; 46(10): 943-954. doi: 10.1093/eurheartj/ehae880.
9. Jalepalli SK, Gupta P, Dekker ALAJ, Bermejo I, Kar S. Development and validation of multicentre study on novel Artificial Intelligence-based Cardiovascular Risk Score (AICVD). *Fam Med Community Health* [Internet]. 18 Jan 2024 [Citado em 1 Jun 2026].
10. Haimovich JS, Kolossváry M, Alam R, Padrós-Valls R, Lu MT, Aguirre AD. Risk stratification of chest pain in the emergency department using artificial intelligence applied to electrocardiograms. *Open Heart* [Internet]. 1 Set 2025 [Citado em 1 Jun 2026]; 12(2): e003343. Disponível em: <https://openheart.bmj.com>. doi: 10.1136/openhrt-2025-003343.
11. Jung JH, Lee K, Chang K, Ahn Y, Her SH, Lee S. Comparison of the Prognostic Performance of Various Machine Learning Models in Patients with Acute Myocardial Infarction: Results from the COREA-AMI Registry. *Medicina (Kaunas)* [Internet]. 2 Out 2025 [Citado em 1 Jun 2026]; 61(10): 1783. Disponível em: <https://www.mdpi.com/1648-9144/61/10/1783>.
12. Perrone A, Khoshgoftaar TM. A review of machine learning applications in heart health. *Biomed Eng Online* [Internet]. 11 Ago 2025 [Citado em 1 Jun 2026]; 24(1): 99. Disponível em: <https://biomedical-engineering-online.biomedcentral.com>. doi: 10.1186/s12938-025-01430-4.
13. Stătescu C, Anghel L, Tudurachi BS, Leonte A, Benchea LC, Sascău RA. From Classic to Modern Prognostic Biomarkers in Patients with Acute Myocardial Infarction. *Int J Mol Sci* [Internet]. 15 Ago 2022 [Citado em 1 Jun 2026]; 23(16): 9168. Disponível em: <https://www.mdpi.com/journal/ijms>. doi: 10.3390/ijms23169168.
14. Roseiro M, Henriques J, Paredes S, Rocha T, Sousa J. An interpretable machine learning approach to estimate the influence of inflammation biomarkers on cardiovascular risk assessment. *Comput Methods Programs Biomed*. Mar 2023; 230: 107347. doi: 10.1016/j.cmpb.2023.107347.
15. Sousa S, Paredes S, Rocha T, Henriques J, Sousa J, Gonçalves L. Machine learning models' assessment: trust and performance. *Med Biol Eng Comput* [Internet]. Nov 2024 [Citado em 1 Jun 2026]; 62(11): 3397-3410. Disponível em: <https://link.springer.com/journal/11517>. doi: 10.1007/s11517-024-03145-5.
16. PAGE, Matthew J. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, [s. l.], v. 372, n. 71, p. 1-9, 29 mar. 2021. Disponível em: <https://doi.org/10.1136/bmj.n71>. Acesso em: 12 jun. 2026.

ENDEREÇO CORRESPONDÊNCIA

SUZAN KELLY MACEDO

5ª avenida, s/n - Setor Leste Universitário - Goiânia/GO, Brasil.

E-mail: suzan_macedo@discente.ufg.br

EDITORIA E REVISÃO

Editores chefes:

Waldemar Naves do Amaral - <http://lattes.cnpq.br/4092560599116579> - <https://orcid.org/0000-0002-0824-1138>

Nílzio Antônio da Silva - <http://lattes.cnpq.br/1780564621664455> - <https://orcid.org/0000-0002-6133-0498>

Autores:

Suzan Kelly Macedo - <http://lattes.cnpq.br/3855119143627159> - <https://orcid.org/0009-0004-8978-7387>

Bruna de Souza Ferreira - <http://lattes.cnpq.br/4672495860254028> - <https://orcid.org/0009-0004-9240-9838>

Karoline José de Deus Souza Gomes - <http://lattes.cnpq.br/4088280889938823> - <https://orcid.org/0009-0009-0967-1656>

Guilherme Tomas Luciano - <http://lattes.cnpq.br/5992287003978001> - <https://orcid.org/0009-0002-9281-0897>

Fabiano Inácio de Souza - <http://lattes.cnpq.br/8305270225089632> - <https://orcid.org/0000-0001-5862-4674>

Revisão Bibliotecária: Izabella Goulart

Revisão Ortográfica: Dario Alvares

Tradução: Soledad Montalbetti Magri

Recebido: 24/08/26. Aceito: 27/08/26. Publicado em: 05/10/2026.