

## Predição de risco cardiovascular na estratégia saúde da família: Uma revisão de algoritmos de machine learning

Carlos Henrique Passos Mairink<sup>1</sup>

**Resumo:** A doença cardiovascular permanece como a principal causa de morbimortalidade global, o que demanda estratégias de prevenção primária mais robustas e adaptadas à realidade dos sistemas de saúde. O presente estudo tem como objetivo realizar uma revisão sistemática da literatura sobre a aplicação de algoritmos de Machine Learning para a predição de risco cardiovascular no contexto da Atenção Primária à Saúde, especificamente na Estratégia Saúde da Família. A metodologia adotada consistiu em uma revisão de natureza narrativa e qualitativa, realizada na base de dados PubMed, compreendendo publicações entre janeiro de 2023 e dezembro de 2026, com foco na comparação entre modelos de inteligência artificial e escores de risco tradicionais. Os resultados evidenciam que algoritmos de aprendizado de máquina, como Random Forest, XGBoost e Deep Learning, superam consistentemente os métodos estatísticos convencionais em acurácia e discriminação de risco, além de viabilizarem o uso de biomarcadores digitais de baixo custo e a integração de determinantes sociais e variáveis de saúde mental nos modelos preditivos. Conclui-se que a implementação dessas tecnologias, aliada à telemedicina, apresenta-se como uma estratégia custo-efetiva e promissora para a personalização do cuidado e a otimização de recursos no Sistema Único de Saúde.

**Palavras-chave:** doenças cardiovasculares; inteligência artificial; aprendizado de máquina; atenção primária à saúde; estratégia saúde da família.

*Cardiovascular risk prediction in the family health strategy: A review of machine learning algorithms*

**Abstract:** Cardiovascular disease remains the leading cause of global morbidity and mortality, necessitating robust primary prevention

<sup>1</sup> Professor Universitário, Doutor, Mestre, Pós-graduado e Discente do Curso de Medicina da Uninassau – Faculdade Uninassau Belo Horizonte. E-mail: passosmairink@gmail.com. E-mail: passosmairink@gamil.com

strategies adapted to the reality of health systems. This study aims to conduct a systematic literature review on the application of Machine Learning algorithms for cardiovascular risk prediction within the context of Primary Health Care, specifically in the Family Health Strategy. The methodology employed consisted of a narrative and qualitative review conducted in the PubMed database, covering publications between January 2023 and December 2026, focusing on the comparison between artificial intelligence models and traditional risk scores. The results indicate that machine learning algorithms, such as Random Forest, XGBoost, and Deep Learning, consistently outperform conventional statistical methods in accuracy and risk discrimination, in addition to enabling the use of low-cost digital biomarkers and the integration of social determinants and mental health variables into predictive models. It is concluded that the implementation of these technologies, combined with telemedicine, presents a cost-effective and promising strategy for personalized care and resource optimization in the Unified Health System

**Keywords:** cardiovascular diseases; artificial intelligence; machine learning; primary health care; family health strategy.

## 1 INTRODUÇÃO

As doenças cardiovasculares constituem o maior desafio contemporâneo para a saúde pública global, mantendo-se como a causa predominante de óbitos e incapacidades. No Brasil, o cenário epidemiológico recente sofreu alterações significativas decorrentes da pandemia de COVID-19, evento que exacerbou as taxas de mortalidade e revelou a fragilidade de pacientes com comorbidades. A análise de dados entre 2021 e 2022 demonstra um excesso de óbitos circulatórios, sugerindo que a infecção viral atuou como um catalisador para eventos cardiovasculares, exigindo uma reavaliação das políticas de vigilância (Leite; Guimarães; Sobral, 2025).

A fisiopatologia dessas doenças envolve uma interação complexa entre genética e comportamentos de risco, onde o sedentarismo se consolidou como um fator modificável de alta prevalência, contribuindo diretamente para

hipertensão e diabetes (Maciel et al., 2025). Nesse contexto, o tema deste estudo foca na Estratégia Saúde da Família, que atua como o locus de cuidado longitudinal. A prevenção primária nas unidades básicas tem o potencial de mitigar o impacto de doenças crônicas, mas o sucesso dessas iniciativas depende da capacidade de identificar corretamente os indivíduos de maior risco (Fonseca et al., 2023).

O problema central reside na estratificação tradicional baseada em modelos estrangeiros, como o Escore de Framingham. A aplicação dessas ferramentas em populações miscigenadas, como a brasileira, frequentemente resulta em calibração inadequada; a validação na coorte ELSA-Brasil evidenciou discrepâncias que apontam para a necessidade urgente de ferramentas que considerem as especificidades locais (Camargos et al., 2024).

A justificativa para esta pesquisa fundamenta-se na promessa do Machine Learning e da Inteligência Artificial em superar as limitações dos modelos estatísticos clássicos. Esses algoritmos processam grandes volumes de dados heterogêneos para uma discriminação de risco mais precisa e personalizada (Liu et al., 2023).

Além dos fatores biológicos, a IA permite integrar determinantes sociais de saúde, visando uma abordagem mais equânime em países de média renda (Santamaria-Garcia et al., 2023). A implementação tecnológica enfrenta desafios, mas a telemedicina surge como solução para levar essa expertise a áreas remotas, utilizando algoritmos treinados em bases nacionais (Oliveira et al., 2025).

Ainda como justificativa, destaca-se que modelos de aprendizado de máquina que incorporam variáveis psicológicas, como depressão e ansiedade, apresentam acurácia superior (Dorraki et al., 2024). A utilização de proteômica

combinada com IA também revelou que modelos personalizados superam escores tradicionais como o Framingham e o SCORE2-Diabetes (Yu et al., 2025). Sob a ótica da equidade, é essencial mitigar vieses de algoritmos desenvolvidos no hemisfério norte para reduzir o fosso assistencial brasileiro (Garcha; Phillips, 2023). Economicamente, a identificação precoce via IA é custo-efetiva, favorecendo a sustentabilidade do sistema público (Wu et al., 2025).

Por fim, tem-se que o objetivo deste trabalho é realizar uma revisão da literatura sobre a aplicação de Machine Learning na predição de risco cardiovascular, analisando sua eficácia e potencial de implementação na Estratégia Saúde da Família.

## 2 EPIDEMIOLOGIA E DESAFIOS DA ESTRATIFICAÇÃO DE RISCO

A transição epidemiológica no Brasil é marcada pelo aumento das doenças crônicas não transmissíveis, com as cardiovasculares no topo da mortalidade, cenário agravado pela recente crise sanitária global. O excesso de óbitos por doenças isquêmicas e cerebrovasculares durante e após a pandemia de COVID-19 indica uma vulnerabilidade que exige monitoramento. A interação entre infecções virais e o substrato cardiovascular pré-existente alterou padrões de risco, demandando modelos preditivos dinâmicos que incorporem variáveis emergentes (Leite; Guimarães; Sobral, 2024).

O sedentarismo e outros riscos comportamentais desafiam a Estratégia Saúde da Família, que atua na modificação de estilos de vida em contextos sociais adversos. A mortalidade por baixa atividade física concentra-se em áreas com menor IDH e pouco acesso a espaços de lazer. Reconhecer a inatividade física como determinante maior reforça a necessidade de ferramentas de estratificação que considerem o ambiente e o comportamento, indo além dos parâmetros biológicos (Maciel et al., 2025).

A adequação de escores tradicionais à realidade brasileira é questionada, apontando-se a necessidade de recalibração para modelos mais aderentes à nossa diversidade. A comparação entre escores internacionais, como o SCORE-2, na coorte ELSA-Brasil, demonstrou falhas na calibração, superestimando ou subestimando o risco em diferentes estratos. Essa discrepância sugere que a importação direta de algoritmos sem adaptação compromete a eficácia da prevenção primária no Brasil (Pedroso Camargos et al., 2024).

Uma abordagem complementar envolve os percentis de risco, que situam o indivíduo perante seus pares de mesma idade e sexo, facilitando a percepção da necessidade de intervenção. A determinação desses percentis para a população brasileira oferece uma perspectiva relativa motivadora para pacientes jovens com baixo risco absoluto, mas alto risco relativo. Essa estratégia, aliada a modelos calibrados, aprimora a decisão clínica compartilhada e a adesão na atenção primária (Cesena et al., 2023).

A eficácia preventiva depende da capacidade do sistema de implementar intervenções comunitárias contínuas. Experiências em clínicas de São Paulo mostram que programas estruturados de manejo cardiovascular alcançam resultados positivos no controle de hipertensão e dislipidemia. Contudo, a sustentabilidade e otimização de recursos exigem que as intervenções priorizem indivíduos com maior probabilidade de eventos, reforçando a centralidade de uma triagem precisa (Fonseca et al., 2023).

A desigualdade social exerce impacto profundo no risco cardiovascular, muitas vezes não capturado por variáveis clínicas tradicionais. A literatura alerta para o viés algorítmico em inteligência artificial que ignora disparidades de raça, gênero e classe. A revisão de novos algoritmos deve priorizar a equidade, buscando modelos robustos e justos para todos os segmentos atendidos pelo SUS (Garcha; Phillips, 2023).

O envelhecimento populacional traz desafios à predição de risco, pois modelos tradicionais perdem acurácia em idades avançadas devido a comorbidades. Técnicas de aprendizado de máquina em coortes de idosos mostram-se promissoras para refinar a predição de morte súbita, utilizando dados de prontuários eletrônicos. Tais algoritmos permitem uma estratificação nuançada, evitando excessos ou omissões de tratamento nessa população (Li et al., 2025).

Regionalmente, a América Latina busca soluções de saúde digital compatíveis com sistemas fragmentados e recursos escassos. A pesquisa sobre IA na gestão cardiovascular cresce, adaptando tecnologias globais às necessidades locais e superando barreiras de infraestrutura. A colaboração entre pesquisa e setor público é fundamental para criar um ecossistema de inovação e validar algoritmos autóctones, reduzindo a dependência tecnológica (Lemes; Gonzalez; Chatterjee, 2025).

### 3 COMPARATIVO DE ALGORITMOS: MACHINE LEARNING X TRADICIONAL

A superioridade dos algoritmos de Machine Learning sobre os métodos estatísticos convencionais na predição de risco cardiovascular tem sido corroborada por uma vasta quantidade de evidências recentes, destacando-se pela maior acurácia e capacidade de generalização. Uma meta-análise abrangente comparando modelos de aprendizado de máquina com escores tradicionais utilizando dados de prontuários eletrônicos revelou que algoritmos como Random Forest e Deep Learning apresentam desempenho significativamente superior. A área sob a curva (AUC) agregada para os modelos de Machine Learning atingiu valores elevados, superando consistentemente os escores clínicos padrão como o QRISK3 e o ASCVD, o que justifica a transição tecnológica em curso (Liu et al., 2025).

O algoritmo Random Forest, que opera através da construção de múltiplas árvores de decisão durante o treinamento, tem se destacado pela sua robustez em lidar com dados ruidosos e pela sua capacidade de evitar o sobreajuste (overfitting). Em estudos comparativos utilizando bases de dados públicas padronizadas, a aplicação de Random Forest otimizado por algoritmos de busca avançada alcançou taxas de acurácia superiores a 90% na detecção de doença arterial coronariana. Esse desempenho contrasta com a acurácia significativamente menor obtida pelos escores de risco tradicionais nas mesmas bases de dados, evidenciando o potencial do aprendizado de máquina para refinar o diagnóstico clínico (Olawade et al., 2025).

O algoritmo XGBoost (Extreme Gradient Boosting) emergiu como uma das ferramentas mais poderosas para a predição de risco, oferecendo alta performance computacional e precisão em grandes conjuntos de dados. A aplicação do XGBoost em estudos populacionais permitiu a identificação de preditores de risco específicos para cada sexo, superando as limitações dos modelos que aplicam os mesmos pesos para homens e mulheres. A capacidade de segmentar e personalizar a análise de risco baseada no sexo biológico representa um avanço importante para a medicina de precisão, corrigindo distorções históricas na avaliação do risco cardiovascular em mulheres (Topranin et al., 2025).

A aplicação de algoritmos de Machine Learning não se restringe à incorporação de novas variáveis, mas também à extração de maior valor preditivo das variáveis clínicas já disponíveis na rotina médica. Pesquisas demonstraram que, mesmo utilizando apenas os fatores de risco convencionais do Escore de Framingham, algoritmos como Support Vector Machine (SVM) e árvores de decisão conseguem prever a mortalidade por todas as causas com maior precisão do que a regressão logística original. Isso indica que a limitação dos

escores atuais reside, em grande parte, na simplicidade dos modelos matemáticos utilizados, e não necessariamente na ausência de dados clínicos adicionais (Huang et al., 2023).

A adaptação de modelos preditivos para populações específicas de países em desenvolvimento é uma área onde o Machine Learning tem demonstrado grande utilidade, permitindo a criação de ferramentas locais mais precisas do que as genéricas. O desenvolvimento do escore SLCVD para a população do Sri Lanka, utilizando técnicas de aprendizado de máquina, exemplifica como dados locais podem ser usados para superar o desempenho das cartas de risco da Organização Mundial da Saúde. A validação desses modelos regionais confirma que a especificidade populacional é um componente chave para a acurácia da predição de risco em contextos não ocidentais (Mettananda et al., 2024).

A triagem oportunística em registros eletrônicos de saúde, facilitada por algoritmos de aprendizado de máquina, apresenta-se como uma estratégia eficiente para identificar pacientes de alto risco que, de outra forma, passariam despercebidos. Uma revisão de escopo sobre métodos de ensemble learning aplicados a prontuários eletrônicos sugere que a combinação de múltiplos modelos preditivos pode aumentar a sensibilidade da detecção de doenças cardiovasculares na atenção primária. Essa abordagem permite uma vigilância contínua e automatizada da população adscrita, otimizando o tempo dos profissionais de saúde e direcionando a atenção para os casos mais urgentes (Stevens et al., 2023).

A integração de dados de proteômica com algoritmos de aprendizado de máquina representa a fronteira da predição de risco, permitindo a identificação de assinaturas moleculares complexas associadas a complicações cardiovasculares. O uso de Random Survival Forests para analisar perfis proteicos em pacientes com diabetes tipo 2 resultou em modelos preditivos de

alta performance, superiores aos escores clínicos estabelecidos. Embora o custo dessas tecnologias ainda limite sua aplicação em massa, elas sinalizam o futuro da estratificação de risco, onde a biologia de sistemas será integrada à prática clínica através da inteligência artificial (Yu et al., 2025).

A interpretabilidade dos modelos de Machine Learning, frequentemente apontada como uma barreira para a adoção clínica, tem sido aprimorada através do uso de técnicas de Inteligência Artificial Explicável (XAI). A aplicação de métodos como valores SHAP em modelos XGBoost permite aos clínicos visualizar quais variáveis específicas contribuíram para a classificação de risco de um determinado paciente. Essa transparência é fundamental para construir confiança na tecnologia e para capacitar os médicos da Estratégia Saúde da Família a explicarem as decisões terapêuticas aos seus pacientes de forma clara e fundamentada (Zhang et al., 2026).

#### **4 NOVAS FONTES DE DADOS E TECNOLOGIAS EMERGENTES**

O advento do Deep Learning possibilitou a transformação de exames de imagem rotineiros em poderosos biomarcadores de risco cardiovascular, ampliando o escopo da propedêutica médica. A análise automatizada de radiografias de tórax por redes neurais profundas demonstrou ser capaz de estimar o risco de eventos cardiovasculares maiores em dez anos, extraindo informações prognósticas que não são visíveis ao olho humano. Essa abordagem inovadora valoriza um exame de baixo custo e amplamente disponível na atenção primária, permitindo uma estratificação de risco oportunística sem exposição adicional à radiação ou custos elevados (Weiss et al., 2024).

A utilização de imagens de retina como uma janela para a avaliação da saúde vascular sistêmica tem ganhado destaque com o desenvolvimento de algoritmos de inteligência artificial capazes de analisar a microvasculatura ocular. Modelos de Deep Learning treinados em retinografias de pacientes

diabéticos conseguiram prever desfechos cardiovasculares com uma eficácia comparável ou até superior aos escores de risco clínico tradicionais. A portabilidade das câmeras de retina modernas e a automação da análise tornam essa tecnologia ideal para campanhas de rastreamento em unidades básicas de saúde e comunidades remotas (Syed et al., 2025).

O eletrocardiograma, exame fundamental na cardiologia, foi revitalizado pela aplicação de inteligência artificial, que permite a extração de informações prognósticas sutis a partir do traçado elétrico. A plataforma AIRE, validada em coortes transnacionais que incluem pacientes brasileiros, utiliza redes neurais para estimar não apenas o risco de mortalidade, mas também a curva de sobrevivência individual a partir de um único eletrocardiograma. A capacidade de processar exames digitalizados a partir de imagens amplia a aplicabilidade dessa ferramenta em locais onde os equipamentos de ECG ainda não são nativamente digitais, promovendo a interoperabilidade (Sau et al., 2024).

Os dispositivos vestíveis, ou wearables, representam uma fonte inesgotável de dados fisiológicos contínuos que podem ser monitorados e analisados em tempo real por algoritmos de aprendizado de máquina. A fusão de sinais de múltiplos sensores de fotopletismografia em dispositivos de pulso, processada por algoritmos de Machine Learning, permite a estimativa contínua da pressão arterial com boa generalização entre indivíduos. Essa tecnologia supera as limitações das medidas pontuais de consultório, oferecendo um perfil hemodinâmico mais completo e realista do paciente em seu ambiente cotidiano (Wang; Tian; Zhu, 2023).

A intervenção no estilo de vida, pilar da prevenção cardiovascular, pode ser potencializada pelo uso de sistemas de coaching autônomo baseados em inteligência artificial e dados de dispositivos vestíveis. Ensaios clínicos demonstraram que o uso de aplicativos que fornecem orientações personalizadas

baseadas nos dados de atividade física e pressão arterial do paciente resulta em reduções significativas nos níveis pressóricos. A automação do acompanhamento aumenta o engajamento do paciente e reduz a carga de trabalho das equipes de saúde, permitindo um monitoramento remoto eficaz e escalável (Leitner et al., 2024).

A análise de ultrassonografia carotídea assistida por Deep Learning oferece uma avaliação direta e não invasiva da carga aterosclerótica, identificando características de vulnerabilidade da placa que escapam à análise convencional. A automação da detecção de neovascularização intraplaca e outras características de risco por sistemas de inteligência artificial melhora a predição de eventos cerebrovasculares e coronarianos. Essa tecnologia pode transformar o ultrassom point-of-care em uma ferramenta poderosa de estratificação de risco na atenção primária, desde que haja disponibilidade de equipamento e treinamento básico (Bhagawati et al., 2024).

O conceito de exposoma, que engloba a totalidade das exposições ambientais e de estilo de vida ao longo da vida, pode ser integrado aos modelos de risco cardiovascular através de técnicas de inteligência artificial. Modelos que combinam dados de exposoma, como poluição do ar, dieta e níveis de estresse, com dados clínicos tradicionais utilizando Random Forest, demonstraram desempenho preditivo robusto, com a vantagem de focar em fatores modificáveis. Essa abordagem holística é particularmente relevante para a saúde pública, pois permite identificar alvos de intervenção ambiental e comunitária para a redução do risco cardiovascular (Shahbazi; Nowaczyk, 2025).

A aplicação de modelos de Deep Learning em coortes de idosos saudáveis revelou que algoritmos neurais avançados são superiores aos modelos de regressão de Cox tradicionais na predição de risco cardiovascular nessa faixa etária. A capacidade desses modelos de lidar com a complexidade das múltiplas

comorbidades e com a natureza censurada dos dados de sobrevivência permite uma estimativa de risco mais precisa. A implementação desses algoritmos pode otimizar a indicação de terapias preventivas em idosos, reduzindo o número necessário de tratamentos para prevenir um evento e minimizando a polifarmácia (Teshale et al., 2025).

## **5 SAÚDE MENTAL E INTEGRAÇÃO DE DETERMINANTES**

A relação intrínseca entre saúde mental e doença cardiovascular é cada vez mais reconhecida, exigindo modelos preditivos que integrem variáveis psicológicas para uma avaliação de risco completa. A incorporação de dados sobre depressão e ansiedade em modelos de ensemble machine learning resultou em um aumento substancial na acurácia da predição de doenças cardiovasculares, demonstrando que a saúde mental é um componente crítico do risco. Essa constatação reforça a necessidade de uma abordagem biopsicossocial na Estratégia Saúde da Família, onde a triagem de saúde mental deve ser integrada à avaliação cardiovascular de rotina (Dorraki et al., 2024).

Pacientes portadores de transtornos mentais graves, como esquizofrenia e transtorno bipolar, apresentam um risco cardiovascular desproporcionalmente elevado, que muitas vezes é subestimado pelos escores de risco gerais. Modelos de predição desenvolvidos especificamente para essas populações, utilizando aprendizado de máquina em grandes registros nacionais, mostram que a inclusão de variáveis como comorbidades psiquiátricas e uso de psicofármacos aprimora significativamente a estimativa de risco. A validação transnacional desses modelos sugere que é possível criar ferramentas robustas e generalizáveis para proteger a saúde cardiovascular dessa população vulnerável (Nielsen et al., 2026).

A presença de depressão pode alterar a manifestação clínica de sintomas cardiovasculares, como a dor torácica, complicando o diagnóstico e a

estratificação de risco na prática clínica diária. Análises baseadas em aprendizado de máquina revelam que a depressão modifica o valor preditivo da localização da dor torácica para doença arterial coronariana, o que pode levar a erros diagnósticos se não for devidamente considerado. Modelos algorítmicos que integram o status de saúde mental conseguem ajustar a interpretação dos sintomas físicos, melhorando a acurácia diagnóstica em pacientes com comorbidades psiquiátricas (Malik et al., 2026).

Em pacientes que sofreram infarto do miocárdio, a identificação precoce de depressão e ansiedade é crucial para o prognóstico e a recuperação, mas frequentemente negligenciada. O uso de algoritmos de classificação como Random Forest, alimentados por dados clínicos e de variabilidade da frequência cardíaca, tem se mostrado eficaz na detecção de pacientes em risco de desenvolver transtornos mentais pós-infarto. A estratificação de risco psicossocial permite a implementação tempestiva de intervenções de suporte, que podem melhorar a adesão ao tratamento e reduzir a recorrência de eventos cardiovasculares (Moreira et al., 2025).

A identificação de subgrupos de risco cardiovascular em adolescentes com transtorno depressivo maior através de técnicas de aprendizado não supervisionado revelou a existência de perfis biológicos distintos dentro de uma mesma categoria diagnóstica. O uso de algoritmos de clustering permitiu distinguir adolescentes que, apesar de apresentarem sintomas depressivos semelhantes, possuem riscos cardiometabólicos muito diferentes. Essa descoberta sublinha a importância da medicina de precisão desde a juventude, permitindo intervenções preventivas focadas nos subgrupos de maior risco biológico (Khalfan et al., 2024).

A utilização de biomarcadores sanguíneos inovadores em conjunto com modelos de aprendizado de máquina tem permitido avanços na compreensão da

ligação biológica entre insuficiência cardíaca e depressão. A identificação de índices inflamatórios e metabólicos como preditores robustos de risco de depressão em pacientes com insuficiência cardíaca sugere mecanismos fisiopatológicos compartilhados. A interpretabilidade desses modelos facilita a aplicação clínica e aponta para novas vias terapêuticas que podem beneficiar simultaneamente a saúde física e mental do paciente (Tao et al., 2025).

A computação avançada e a bioinformática têm explorado a identificação de neuropeptídeos como potenciais biomarcadores integrados para condições neurológicas e cardiovasculares, como a ansiedade. Revisões sobre o uso de aprendizado de máquina para a identificação e análise de neuropeptídeos indicam que essas moléculas podem servir como alvos futuros para diagnóstico e tratamento. O mapeamento dessas vias de sinalização por inteligência artificial abre perspectivas para o desenvolvimento de testes diagnósticos que avaliem o risco neuro-cardíaco de forma integrada (Rahmani; Kalankesh; Ferdousi, 2024).

Intervenções digitais que utilizam agentes conversacionais baseados em inteligência artificial mostram potencial para promover mudanças de comportamento que beneficiam tanto a saúde mental quanto a cardiovascular. Ensaio clínico com assistentes digitais que utilizam processamento de linguagem natural e aprendizado por reforço para personalizar o incentivo à atividade física indicam resultados promissores no engajamento dos usuários. Na atenção primária, essas ferramentas podem estender o alcance das equipes de saúde, oferecendo suporte contínuo e personalizado para o manejo do estresse e a promoção de hábitos saudáveis (Vandelanotte et al. 2025).

## **6 CUSTO-EFETIVIDADE E DESAFIOS ECONÔMICOS**

A avaliação econômica da incorporação de inteligência artificial na saúde cardiovascular tem demonstrado resultados promissores, sugerindo que essas tecnologias podem ser não apenas clinicamente eficazes, mas também

financeiramente sustentáveis. Modelos de simulação indicam que o rastreamento de disfunção ventricular esquerda assintomática através de eletrocardiogramas assistidos por inteligência artificial apresenta uma relação custo-efetividade muito favorável quando comparado ao cuidado padrão. A detecção precoce permite o início de tratamentos preventivos acessíveis, que evitam a progressão para insuficiência cardíaca sintomática e reduzem os custos associados a hospitalizações (Thao et al., 2025).

O rastreamento oportunístico de cálcio coronariano em tomografias de tórax realizadas por outras indicações clínicas, automatizado por algoritmos de inteligência artificial, revelou-se uma estratégia economicamente dominante em diversos cenários. A capacidade da inteligência artificial de extrair informações de risco cardiovascular de exames já realizados elimina a necessidade de tempo adicional do radiologista e maximiza o valor dos recursos diagnósticos já investidos. Em sistemas públicos de saúde com filas de espera, essa abordagem de "reciclagem" de dados para prevenção secundária representa uma eficiência alocativa significativa (Pickhardt; Correale; Hassan, 2023).

A implementação de rastreamento sistemático para fibrilação atrial em populações rurais ou com acesso limitado a especialistas, utilizando eletrocardiogramas analisados por inteligência artificial, mostrou-se uma alternativa custo-efetiva. A análise de sensibilidade econômica sugere que a viabilidade dessa estratégia depende crucialmente da taxa de encaminhamento após um resultado positivo, destacando a importância da especificidade dos algoritmos para evitar a sobrecarga do sistema de referência. A tecnologia atua, assim, como um filtro qualificado que otimiza o fluxo de pacientes na rede de atenção à saúde (Liu et al., 2025).

Uma revisão sistemática abrangente das avaliações econômicas de intervenções baseadas em inteligência artificial na saúde confirmou que a grande

maioria dos estudos aponta para relações de custo-efetividade favoráveis ou de dominação econômica. No entanto, a metodologia dessas avaliações precisa evoluir para capturar as características dinâmicas da inteligência artificial, como a escalabilidade, o aprendizado contínuo e os custos de implementação e manutenção da infraestrutura digital. A generalização desses resultados para o contexto do SUS exige estudos locais que considerem os custos reais dos procedimentos e a estrutura de financiamento da saúde pública no Brasil (Wu et al., 2026).

Apesar do cenário econômico favorável, a adoção de novas tecnologias na atenção primária deve ser precedida por uma análise cuidadosa dos custos de oportunidade e das prioridades de investimento em saúde. A alocação de recursos para softwares de inteligência artificial deve ser balanceada com a necessidade de manter a cobertura básica e o acesso a medicamentos essenciais. A evidência sugere que o maior retorno sobre o investimento ocorre quando a tecnologia é usada para otimizar processos existentes e prevenir eventos de alto custo, liberando recursos para outras áreas do sistema (Wu et al., 2025).

A equidade no acesso às tecnologias de predição de risco é uma preocupação ética e econômica central, pois a introdução de ferramentas avançadas não deve ampliar as disparidades em saúde já existentes. Se os algoritmos forem disponibilizados apenas em centros de excelência ou para populações com maior nível socioeconômico, o benefício populacional será limitado e as desigualdades serão exacerbadas. A implementação na Estratégia Saúde da Família, que cobre a maior parte da população vulnerável, é a estratégia mais eficaz para garantir que os benefícios da inteligência artificial sejam distribuídos de forma justa (Garcha; Phillips, 2023).

A infraestrutura tecnológica necessária para suportar a inteligência artificial, incluindo conectividade de internet e hardware adequado nas unidades

básicas de saúde, representa um investimento inicial significativo que deve ser considerado nas análises de custo. No entanto, soluções baseadas em dispositivos móveis e processamento local (edge computing) podem reduzir a dependência de infraestrutura pesada, tornando a implementação mais viável economicamente em áreas remotas. A escolha de tecnologias adaptadas à realidade local é fundamental para garantir a sustentabilidade dos projetos de saúde digital (Keivanimehr; Akbari, 2025).

A regulação e a certificação de algoritmos de inteligência artificial como dispositivos médicos são etapas essenciais para garantir a segurança e a eficácia clínica, mas também envolvem custos e processos burocráticos. O desenvolvimento de um marco regulatório claro e ágil no Brasil é necessário para incentivar a inovação e a adoção dessas tecnologias pelo sistema público. A validação clínica rigorosa e transparente é o caminho para mitigar riscos e assegurar que o investimento público em inteligência artificial resulte em benefícios reais para a saúde da população (Lemes et al., 2025).

## 7 METODOLOGIA

Esta pesquisa caracteriza-se como uma revisão sistemática da literatura, de natureza narrativa e qualitativa, com o objetivo de sintetizar as evidências mais recentes sobre a aplicação de inteligência artificial na cardiologia preventiva. A busca bibliográfica foi realizada exclusivamente na base de dados PubMed, reconhecida por indexar publicações de alto rigor científico na área biomédica. O recorte temporal estabelecido compreendeu o período de janeiro de 2023 a dezembro de 2026, garantindo a atualidade dos dados e a inclusão de estudos que refletem o cenário pós-pandemia e os avanços tecnológicos mais recentes.

Para a seleção dos artigos, utilizou-se uma estratégia de busca estruturada com combinações de descritores controlados e palavras-chave livres, incluindo

termos como "cardiovascular risk", "machine learning", "primary care", "artificial intelligence", "Brazil", "deep learning" e "family health strategy". Os critérios de inclusão priorizaram estudos originais, revisões sistemáticas e ensaios clínicos que abordassem a comparação entre algoritmos de aprendizado de máquina e escores tradicionais, aplicações em atenção primária, estudos com dados brasileiros ou latino-americanos e análises de custo-efetividade. Foram excluídos artigos de opinião sem dados empíricos, estudos focados exclusivamente em procedimentos cirúrgicos de alta complexidade sem relação com a prevenção e publicações fora do intervalo temporal definido.

A análise dos dados seguiu uma abordagem qualitativa, onde as informações extraídas dos artigos selecionados foram categorizadas por temas centrais: epidemiologia, comparação de algoritmos, novas tecnologias, determinantes sociais/saúde mental e implementação/economia. A síntese dos resultados buscou identificar tendências, consensos e lacunas no conhecimento, com especial atenção para as implicações práticas para a Estratégia Saúde da Família no Brasil. As limitações do estudo incluem a restrição a uma única base de dados e a possibilidade de viés de publicação inerente às revisões narrativas, embora mitigado pela busca sistemática e critérios rigorosos de seleção.

## 8 DISCUSSÃO E RESULTADOS

A análise abrangente da literatura selecionada no período de 2023 a 2025 consolida a evidência de que os algoritmos de Machine Learning representam um avanço significativo e necessário para a estratificação de risco cardiovascular na atenção primária. A superioridade técnica desses modelos, demonstrada consistentemente através de métricas de desempenho robustas como a Área Sob a Curva, decorre de sua capacidade intrínseca de processar a não-linearidade e a complexidade das interações biológicas, superando as limitações dos modelos estatísticos lineares tradicionais. A transição para modelos dinâmicos e de

aprendizado contínuo oferece uma oportunidade sem precedentes para refinar a prevenção primária e secundária.

No contexto brasileiro, a discussão sobre a implementação dessas tecnologias assume contornos de saúde pública e justiça social. A Estratégia Saúde da Família, com sua capilaridade e foco na longitudinalidade do cuidado, posiciona-se como o cenário ideal para a integração de ferramentas de inteligência artificial. A existência de iniciativas maduras de telessaúde, como a Rede de Telessaúde de Minas Gerais, prova que o sistema público brasileiro possui capacidade técnica e operacional para adotar inovações em larga escala. A utilização de dados locais para o treinamento e validação de algoritmos é um passo crucial para garantir a soberania tecnológica e a adequação das ferramentas à diversidade da população brasileira.

A incorporação de novas fontes de dados, como imagens médicas simples e sinais de dispositivos vestíveis, democratiza o acesso a diagnósticos de alta complexidade. A possibilidade de transformar um eletrocardiograma de rotina ou uma fotografia de fundo de olho em biomarcadores prognósticos sofisticados permite que pacientes em regiões remotas tenham seu risco avaliado com precisão comparável à dos grandes centros urbanos. Essa descentralização da tecnologia é fundamental para reduzir as desigualdades regionais em saúde e promover o acesso universal a cuidados de qualidade.

A saúde mental emerge nesta revisão como um componente indissociável do risco cardiovascular, que pode ser finalmente integrado de forma sistemática através da inteligência artificial. A capacidade dos algoritmos de identificar padrões de risco que unem variáveis psicológicas e cardiovasculares reforça a necessidade de uma abordagem clínica integral. O médico de família, apoiado por essas ferramentas, pode atuar de forma mais assertiva na prevenção,

tratando a depressão e a ansiedade não apenas como transtornos mentais, mas como fatores de risco cardiovascular modificáveis.

A viabilidade econômica da inteligência artificial na prevenção cardiovascular é sustentada por evidências crescentes de custo-efetividade e economia de recursos. A automação do rastreamento e a melhoria na especificidade dos diagnósticos reduzem o desperdício com exames desnecessários e focam os recursos terapêuticos nos pacientes que realmente se beneficiarão. A economia gerada a longo prazo pela prevenção de eventos catastróficos, como infartos e derrames, justifica o investimento inicial na modernização da infraestrutura tecnológica das unidades de saúde.

A tabela a seguir apresenta uma síntese de estudos fundamentais analisados nesta revisão, ilustrando a diversidade de abordagens algorítmicas e a consistência dos resultados favoráveis à IA.

Tabela 01

| Autor(es) (Ano)                  | Foco do Estudo / Algoritmo                | Principais Resultados e Desempenho                                                                                                                                                   |
|----------------------------------|-------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Bhagawati et al. (2024)          | Deep Learning em ultrassonografia         | A automação via <i>Deep Learning</i> detectou características de vulnerabilidade da placa em ultrassom, melhorando a predição de eventos cerebrovasculares e coronarianos.           |
| De Martin Topranin et al. (2025) | XGBoost específico por sexo (HUNT Study)  | A aplicação do <i>XGBoost</i> identificou preditores específicos para homens e mulheres, superando as limitações de modelos que aplicam pesos iguais (como o NORRISK 2).             |
| Dorraki et al. (2024)            | Saúde Mental em Ensemble Machine Learning | A incorporação de dados de depressão e ansiedade aos modelos aumentou a acurácia global de 71% para 85%, confirmando a saúde mental como componente crítico do risco.                |
| Huang et al. (2023)              | SVM vs. Escore de Framingham              | Algoritmos como <i>Support Vector Machine</i> (SVM) predisseram mortalidade com maior precisão que a regressão logística, mesmo utilizando apenas os fatores de risco convencionais. |
| Leitner et al. (2024)            | Coaching de Estilo de Vida via AI         | O uso de orientações personalizadas por AI resultou em redução significativa da pressão arterial sistólica (8.1 mmHg) em 24 semanas.                                                 |
| Liu, T. et al. (2024)            | Meta-análise: ML vs. Escores Tradicionais | <i>Machine Learning</i> ( <i>Random Forest</i> , <i>Deep Learning</i> ) superou consistentemente escores tradicionais (QRISK3, ASCVD) na predição de risco em 5-10 anos.             |
| Liu, W. T. et al. (2025)         | Custo-efetividade em Fibrilação Atrial    | O rastreamento de fibrilação atrial por AI em populações rurais mostrou-se uma alternativa custo-efetiva, atuando como filtro qualificado para especialistas.                        |
| Mettananda et al. (2024)         | Escore SLCVD vs. WHO                      | O modelo treinado com dados locais obteve AUC de 0.98, muito superior às cartas genéricas da OMS (AUC                                                                                |

|                                       |                                      |                                                                                                                                                        |
|---------------------------------------|--------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------|
|                                       |                                      | 0.52), provando a importância da especificidade populacional.                                                                                          |
| Nielsen <i>et al.</i> (2026)          | ML em Esquizofrenia                  | Modelos específicos para transtornos mentais graves (usando comorbidades e psicofármacos) melhoraram a estimativa de risco nesta população vulnerável. |
| Olawade <i>et al.</i> (2025)          | <i>Random Forest</i> para CAD        | O algoritmo <i>Random Forest</i> alcançou acurácia superior a 90% na detecção de Doença Arterial Coronariana, lidando bem com dados ruidosos.          |
| Oliveira <i>et al.</i> (2025)         | Telemedicina e <i>Big Data</i>       | Validou a telecardiologia em larga escala (análise de milhões de ECGs) como suporte eficaz à Atenção Primária, garantindo precisão em áreas remotas.   |
| Pedroso Camargos <i>et al.</i> (2024) | Validação no ELSA-Brasil             | Demonstrou que escores importados (PCE, SCORE-2) têm calibração inadequada para brasileiros, indicando a necessidade de recalibração urgente.          |
| Sau <i>et al.</i> (2024)              | Plataforma AIRE (DL em ECG)          | Validou modelo que estima risco de mortalidade e arritmias a partir de um único ECG, útil para locais onde o equipamento não é nativamente digital.    |
| Shahbazi; Nowaczyk (2025)             | <i>Exposome e Random Forest</i>      | A integração de dados ambientais (poluição, dieta) e clínicos resultou em predição robusta, focando em fatores modificáveis de saúde pública.          |
| Syed <i>et al.</i> (2025)             | <i>Deep Learning</i> em Retina       | Imagens de fundo de olho analisadas por AI predisseram desfechos cardiovasculares em diabéticos com eficácia comparável a escores clínicos complexos.  |
| Thao <i>et al.</i> (2024)             | Custo-Efetividade de AI-ECG          | O rastreamento de disfunção ventricular esquerda via AI-ECG foi altamente custo-efetivo comparado ao cuidado padrão, prevenindo hospitalizações.       |
| Weiss <i>et al.</i> (2024)            | <i>Deep Learning</i> em Raio-X (CXR) | Redes neurais estimaram o risco cardiovascular (10 anos) usando radiografias de tórax de rotina, permitindo rastreamento oportunístico de baixo custo. |

Fonte: elaborado pelo autor

## 9 CONCLUSÃO

A presente revisão sistemática permite concluir que a incorporação de algoritmos de Machine Learning na predição de risco cardiovascular representa uma evolução necessária e urgente para a Estratégia Saúde da Família no Brasil. As evidências acumuladas entre 2023 e 2025 demonstram inequivocamente que ferramentas baseadas em inteligência artificial — desde florestas aleatórias até redes neurais profundas — oferecem uma precisão diagnóstica e prognóstica superior aos métodos tradicionais, além de permitirem uma personalização do cuidado que considera a complexidade social e biológica do paciente brasileiro.

A viabilidade técnica e econômica dessas soluções, especialmente quando integradas a estratégias de telemedicina e rastreamento oportunístico, sugere que o Sistema Único de Saúde tem diante de si uma oportunidade singular para qualificar a prevenção primária. A superação das barreiras de implementação

exige, contudo, um esforço coordenado para garantir a equidade algorítmica, a infraestrutura digital nas unidades básicas e a capacitação continuada dos profissionais de saúde. A adoção dessas tecnologias não visa substituir o julgamento clínico, mas instrumentalizar o médico de família com a melhor evidência computacional disponível para promover saúde e salvar vidas.

## REFERÊNCIAS

BHAGAWATI, M. *et al.* Deep learning approach for cardiovascular disease risk stratification and survival analysis on a Canadian cohort. **The International Journal of Cardiovascular Imaging**, [S. l.], v. 40, n. 6, p. 1283-1303, 2024. Disponível em: <https://doi.org/10.1007/s10554-024-03100-3>. Acesso em: 29 jan. 2026.

CESENA, F. Y. *et al.* Percentiles of predicted 10-year cardiovascular disease risk by sex and age in Brazil and their association with estimated risk of long-term atherosclerotic events. **Preventive Medicine**, [S. l.], v. 177, 107755, 2023. Disponível em: <https://doi.org/10.1016/j.ypmed.2023.107755>. Acesso em: 02 jan. 2026.

DE MARTIN TOPRANIN, V. *et al.* Sex-specific cardiovascular disease risk prediction using statistical learning and explainable artificial intelligence: the HUNT Study. **European Journal of Preventive Cardiology**, [S. l.], zwaf135, 2025. Advance online publication. Disponível em: <https://doi.org/10.1093/eurjpc/zwaf135>. Acesso em: 29 jan. 2026.

DORRAKI, M. *et al.* Improving Cardiovascular Disease Prediction With Machine Learning Using Mental Health Data: A Prospective UK Biobank Study. **JACC: Advances**, [S. l.], v. 3, n. 9, 101180, 2024. Disponível em: <https://doi.org/10.1016/j.jacadv.2024.101180>. Acesso em: 13 jan. 2026.

FONSECA, H. A. R. *et al.* Primary Prevention of Cardiovascular Disease at Community Clinics in the State of Sao Paulo, Brazil: Results from the Epidemiological Information Study of Communities. **Global Heart**, [S. l.], v. 18, n. 1, 24, 2023. Disponível em: <https://doi.org/10.5334/gh.1203>. Acesso em: 19 jan. 2026.

GARCHA, I.; PHILLIPS, S. P. Social bias in artificial intelligence algorithms designed to improve cardiovascular risk assessment relative to the Framingham Risk Score: a protocol for a systematic review. **BMJ Open**, [S. l.], v. 13, n. 5, e067638, 2023. Disponível em: <https://doi.org/10.1136/bmjopen-2022-067638>. Acesso em: 15 jan. 2026.

HUANG, Q. *et al.* Framingham risk score conventional risk factors are potent to predict all-cause mortality using machine learning algorithms: a population-based prospective cohort study over 40 years in China. **Journal of Investigative Medicine**, [S. l.], v. 71, n. 6, p. 586-590, 2023. Disponível em: <https://doi.org/10.1177/10815589231169689>. Acesso em: 29 jan. 2026.

KEIVANIMEHR, A. R.; AKBARI, M. TinyML and edge intelligence applications in cardiovascular disease: A survey. *Computers in Biology and Medicine*, [S. l.], v. 186, 109653, 2025. Disponível em: <https://doi.org/10.1016/j.compbimed.2025.109653>. Acesso em: 29 jan.

KHALFAN, A. F. *et al.* Identifying Cardiovascular Disease Risk Endotypes of Adolescent Major Depressive Disorder Using Exploratory Unsupervised Machine Learning. *JAACAP Open*, [S. l.], v. 3, n. 2, p. 291-301, 2024. Disponível em: <https://doi.org/10.1016/j.jaacop.2024.04.004>. Acesso em: 21 jan. 2026.

LEITE, C. E. A.; GUIMARÃES, R. M.; SOBRAL, A. Analysis of mortality by cardiovascular disease subgroups in Brazil before and during the COVID-19 pandemic (2000-2022) by sex and age group. *Revista Brasileira de Epidemiologia*, [S. l.], v. 28, e250033, 2025. Disponível em: <https://doi.org/10.1590/1980-549720250033>. Acesso em: 29 jan. 2026.

LEITNER, J. *et al.* The Effect of an AI-Based, Autonomous, Digital Health Intervention Using Precise Lifestyle Guidance on Blood Pressure in Adults With Hypertension: Single-Arm Nonrandomized Trial. *JMIR Cardio*, [S. l.], v. 8, e51916, 2024. Disponível em: <https://doi.org/10.2196/51916>. Acesso em: 03 jan. 2026.

LEMES, L.; GONZALEZ, M.; CHATTERJEE, P. Review on Artificial Intelligence applied to Cardiovascular Disease Management in Latin America. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, [S. l.], v. 2025, p. 1-6, 2025. Disponível em: <https://doi.org/10.1109/EMBC58623.2025.11251637>. Acesso em: 03 jan. 2026.

LI, Y. *et al.* Machine learning for sudden cardiac death prediction among older adults using community-based electronic health records. *BMC Public Health*, [S. l.], v. 25, n. 1, 3521, 2025. Disponível em: <https://doi.org/10.1186/s12889-025-24724-7>. Acesso em: 04 jan. 2026.

LIU, T. *et al.* Machine learning based prediction models for cardiovascular disease risk using electronic health records data: systematic review and meta-analysis. *European Heart Journal: Digital Health*, [S. l.], v. 6, n. 1, p. 7-22, 2024. Disponível em: <https://doi.org/10.1093/ehjdh/ztae080>. Acesso em: 03 jan. 2026.

LIU, W. *et al.* Machine-learning versus traditional approaches for atherosclerotic cardiovascular risk prognostication in primary prevention cohorts: a systematic review and meta-analysis. *European Heart Journal: Quality of Care & Clinical Outcomes*, [S. l.], v. 9, n. 4, p. 310-322, 2023.

Disponível em: <https://doi.org/10.1093/ehjqcco/qcad017>. Acesso em: 03 jan. 2026.

LIU, W. T. *et al.* Universal Atrial Fibrillation Screening Using Electrocardiographic Artificial Intelligence: A Cost-Effective Approach in Rural Communities. **Journal of Medical Systems**, [S. l.], v. 49, n. 1, 145, 2025.

Disponível em: <https://doi.org/10.1007/s10916-025-02287-9>. Acesso em: 25 jan. 2026.

MACIEL, E. D. S. *et al.* Noncommunicable diseases attributed to low levels of physical activity in Brazil: an epidemiologic Global Burden of Disease Study. **Revista da Associação Médica Brasileira**, [S. l.], v. 71, n. 9, e20250203, 2025. Disponível em: <https://doi.org/10.1590/1806-9282.20250203>. Acesso em: 14 jan. 2026.

MALIK, M. I. *et al.* Machine Learning Reveals How Depression Influences Chest Pain Localisation and Its Predictive Value for Coronary Artery Disease. **The Canadian Journal of Cardiology**, [S. l.], v. 42, n. 1, p. 166-176, 2026.

Disponível em: <https://doi.org/10.1016/j.cjca.2025.09.017>. Acesso em: 22 jan. 2026.

METTANANDA, C. *et al.* Development and validation of a cardiovascular risk prediction model for Sri Lankans using machine learning. **PloS One**, [S. l.], v. 19, n. 10, e0309843, 2024. Disponível em: <https://doi.org/10.1371/journal.pone.0309843>. Acesso em: 15 jan. 2026.

MOREIRA, L. L. *et al.* Predictive modeling of depression and anxiety after myocardial infarction: a study on influential factors and heart rate variability. **Health Information Science and Systems**, [S. l.], v. 13, n. 1, 60, 2025. Disponível em: <https://doi.org/10.1007/s13755-025-00374-2>. Acesso em: 22 jan. 2026.

NIELSEN, S. D. *et al.* Development and external validation of machine learning approaches for risk prediction of cardiovascular disease in individuals with schizophrenia: a nationwide Swedish and Danish study. **BMJ Mental Health**, [S. l.], v. 29, n. 1, e301964, 2026. Disponível em: <https://doi.org/10.1136/bmjment-2025-301964>. Acesso em: 22 jan. 2026.

OLAWADE, D. B. *et al.* Comparative analysis of machine learning models for coronary artery disease prediction with optimized feature selection. **International Journal of Cardiology**, [S. l.], v. 436, 133443, 2025. Disponível em: <https://doi.org/10.1016/j.ijcard.2025.133443>. Acesso em: 27 jan. 2026.

OLIVEIRA, C. R. A. *et al.* Upscaling a regional telecardiology service to a nationwide coverage and beyond: the experience of the Telehealth Network of Minas Gerais. **BMJ Global Health**, [S. l.], v. 10, n. 1, e016692, 2025. Disponível em: <https://doi.org/10.1136/bmjgh-2024-016692>. Acesso em: 28 jan. 2026.

PEDROSO CAMARGOS, A. *et al.* Performance of contemporary cardiovascular risk stratification scores in Brazil: an evaluation in the ELSA-Brasil study. **Open Heart**, [S. l.], v. 11, n. 1, e002762, 2024. Disponível em: <https://doi.org/10.1136/openhrt-2024-002762>. Acesso em: 28 jan. 2026.

PICKHARDT, P. J.; CORREALE, L.; HASSAN, C. AI-based opportunistic CT screening of incidental cardiovascular disease, osteoporosis, and sarcopenia: cost-effectiveness analysis. **Abdominal Radiology**, New York, v. 48, n. 3, p. 1181-1198, 2023. Disponível em: <https://doi.org/10.1007/s00261-023-03800-9>. Acesso em: 13 jan. 2026.

RAHMANI, R.; KALANKESH, L. R.; FERDOUSI, R. Computational approaches for identifying neuropeptides: A comprehensive review. **Molecular Therapy: Nucleic Acids**, [S. l.], v. 36, n. 1, 102409, 2024. Disponível em: <https://doi.org/10.1016/j.omtn.2024.102409>. Acesso em: 13 jan. 2026.

SANTAMARIA-GARCIA, H. *et al.* Factors associated with healthy aging in Latin American populations. **Nature Medicine**, [S. l.], v. 29, n. 9, p. 2248-2258, 2023. Disponível em: <https://doi.org/10.1038/s41591-023-02495-1>. Acesso em: 15 jan. 2026.

SAU, A. *et al.* Artificial intelligence-enabled electrocardiogram for mortality and cardiovascular risk estimation: a model development and validation study. **The Lancet Digital Health**, [S. l.], v. 6, n. 11, p. e791-e802, 2024. Disponível em: [https://doi.org/10.1016/S2589-7500\(24\)00172-9](https://doi.org/10.1016/S2589-7500(24)00172-9). Acesso em: 05 jan. 2026.

SHAHBAZI, Z.; NOWACZYK, S. Towards personalized cardiometabolic risk prediction: A fusion of exposome and AI. **Heliyon**, [S. l.], v. 11, n. 1, e40859, 2024. Disponível em: <https://doi.org/10.1016/j.heliyon.2024.e40859>. Acesso em: 05 jan. 2026.

STEVENS, C. A. *et al.* Ensemble machine learning methods in screening electronic health records: A scoping review. **Digital Health**, [S. l.], v. 9, 20552076231173225, 2023. Disponível em: <https://doi.org/10.1177/20552076231173225>. Acesso em: 23 jan. 2026.

SYED, M. G. *et al.* Deep-learning prediction of cardiovascular outcomes from routine retinal images in individuals with type 2 diabetes. **Cardiovascular**

**Diabetology**, [S. l.], v. 24, n. 1, 3, 2025. Disponível em:

<https://doi.org/10.1186/s12933-024-02564-w>. Acesso em: 06 jan. 2026.

TAO, Y. *et al.* Biomarker-based depression risk prediction in chronic heart failure patients: an interpretable machine learning approach. **Frontiers in Endocrinology**, [S. l.], v. 16, 1737713, 2025. Disponível em:

<https://doi.org/10.3389/fendo.2025.1737713>. Acesso em: 10 jan. 2026.

TESHALE, A. B. *et al.* Artificial intelligence improves risk prediction in cardiovascular disease. **GeroScience**, [S. l.], v. 47, n. 4, p. 5497-5502, 2025.

Disponível em: <https://doi.org/10.1007/s11357-024-01438-z>. Acesso em: 18 jan. 2026.

THAO, V. *et al.* Cost-Effectiveness of Artificial Intelligence-Enabled Electrocardiograms for Early Detection of Low Ejection Fraction: A Secondary Analysis of the Electrocardiogram Artificial Intelligence-Guided Screening for Low Ejection Fraction Trial. **Mayo Clinic Proceedings: Digital Health**, [S. l.], v. 2, n. 4, p. 620-631, 2024. Disponível em:

<https://doi.org/10.1016/j.mcpdig.2024.10.001>. Acesso em: 21 jan. 2026.

VANDELANOTTE, C. *et al.* MoveMentor-examining the effectiveness of a machine learning and app-based digital assistant to increase physical activity in adults: protocol for a randomised controlled trial. **Trials**, [S. l.], v. 26, n. 1, 233, 2025. Disponível em: <https://doi.org/10.1186/s13063-025-08926-3>. Acesso em: 17 jan. 2026.

WANG, L.; TIAN, S.; ZHU, R. A new method of continuous blood pressure monitoring using multichannel sensing signals on the wrist. **Microsystems & Nanoengineering**, [S. l.], v. 9, 117, 2023. Disponível em:

<https://doi.org/10.1038/s41378-023-00590-4>. Acesso em: 11 jan. 2026.

WEISS, J. *et al.* Deep Learning to Estimate Cardiovascular Risk From Chest Radiographs: A Risk Prediction Study. **Annals of Internal Medicine**, [S. l.], v. 177, n. 4, p. 409-417, 2024. Disponível em: <https://doi.org/10.7326/M23-1898>. Acesso em: 13 jan. 2026.

WU, W. T. *et al.* Economic evaluation of AI-assisted technologies in healthcare: A systematic review. **Journal of Food and Drug Analysis**, [S. l.], v. 33, n. 4, p. 487-500, 2025. Disponível em: <https://doi.org/10.38212/2224-6614.3570>. Acesso em: 25 jan. 2026.

YU, B. *et al.* Proteomics-enabled learning machine algorithms enhance the prediction of cardiovascular diseases in patients with type 2 diabetes mellitus.

**Diabetes, Obesity & Metabolism**, [S. l.], v. 27, n. 11, p. 6594-6604, 2025.

Disponível em: <https://doi.org/10.1111/dom.70064>. Acesso em: 28 jan. 2026.

ZHANG, N. *et al.* XGBoost based machine learning prediction model for major adverse cardiovascular events after PCI in STEMI patients. **Scientific Reports**, [S. l.], 2026. Advance online publication. Disponível em:

<https://doi.org/10.1038/s41598-025-34441-1>. Acesso em: 23 jan.